

UNIVERSIDAD CARLOS III DE MADRID

Escuela Politécnica Superior

Departamento de Ingeniería Mecánica



Trabajo Fin de Grado

**MODELO INVERSO DE UN AMORTIGUADOR
MAGNETO-REOLÓGICO UTILIZANDO REDES
NEURONALES**

GRADO EN INGENIERÍA MECÁNICA

2014

Autora: Dña. Paloma Menéndez Pamplona

Tutora: Dra. Dña. M^a Jesús López Boada

AGRADECIMIENTOS

La finalización de este Trabajo de Fin de Grado significa el final de una etapa en mi vida, el final de cuatro años en la Universidad Carlos III. Han sido cuatro años duros, con momentos de tensión y de frustración pero, sobre todo, cuatro años que no podré olvidar. He aprendido, crecido y madurado y he conocido a muchas personas que ahora forman parte de mi vida diaria. El mejor sentimiento que me llevo es que me alegro de haber escogido esta Universidad y que repetiría estos años de nuevo.

Me gustaría dar las gracias en primer lugar a mi tutora M^a Jesús López Boada por su apoyo y dedicación. Por enseñarme un poco más a fondo el mundo de la mecánica del automóvil.

Por supuesto no puedo olvidarme de mi familia, mis padres y mis hermanas, ya que ellos han sufrido día a día todos mis exámenes y momentos de estrés. Especialmente a mi padre, quien me ha ayudado con toda su experiencia y conocimientos, tanto en el proyecto como en la carrera. Igualmente a mi madre quien ha estado pendiente de mí, sobre todo, en aspectos no tan académicos y que sé que siempre va a estar cuando la necesito sea el momento que sea. Gracias por estar apoyándome en todo. No me olvido de mis hermanas ya que ¡mi vida sería mucho más aburrida sin ellas! De la misma manera tengo que agradecer a Santi todo su apoyo, porque de una forma u otra siempre ha estado a mi lado, escuchándome y entendiéndome.

A mis amigos, tanto los nuevos como los de siempre, porque con ellos he vivido muchísimas experiencias que nos han unido aún más. Ya sean los mejores momentos como viajes, salidas y cenas u otros no tan buenos como interminables días en la Universidad, exámenes de cuatro horas, prácticas de laboratorios y sus correspondientes memorias; porque siempre hemos sido capaces de sacar el lado bueno y de superarlos todos juntos, gracias. Todas las anécdotas y recuerdos que hemos vivido a lo largo de estos años quedarán siempre en nuestra memoria. Tengo la suerte de poder decir que me llevo a grandes amigos conmigo y que sé que aunque acabemos la Universidad y cada uno haga su vida, seguiremos en contacto y compartiendo tantos momentos como hasta ahora.

En último lugar y para nada el menos importante quiero mencionar a mi abuelo, porque sé que sería la persona que más orgullosa estaría de mí y a quien le quiero dedicar este Trabajo de Fin de Grado. He realizado el último año de mi carrera así como este proyecto pensando en él en todo momento ya que le hubiese encantado poder leerlo. Él me vio empezar la Universidad, en la misma carrera que él estudió y siguió día a día todos mis pasos por ella; su interés y mi admiración hacia él me han animado a seguir hasta el final y a no rendirme. Gracias Abuelo por ser mi apoyo incondicional.

ABSTRACT

This Final Degree Project aims to model an inverse magneto-rheological damper based on Artificial Neural Networks.

The principal function of the suspension system of a vehicle is to keep the tires in contact to the road, absorbing the vibrations generated in the vehicle and giving security as well as comfort to the passengers. The main components of the suspension system are elastic components such as helical springs or the anti-roll bar and the damper.

There are three types of suspension systems based on the control element: passive suspension, active suspension and semiactive suspension. Passive suspension is design to produce an optimal behavior just in some situations. Active suspension substitutes the damper and elastic elements of the conventional suspension systems by some actuators that produce a force which modifies the damper force. The main problems of this suspension system are that it is very expensive and it has a big energetic cost. To solve these problems semiactive suspension appeared. This third type of suspension system is an intermediate design between the others; it produces variable force by regulating one of the elements of the conventional suspension. Recent studies have shown that this can be possible by adapting some characteristics of the damper.

The damper of a vehicle is a resistant element that reduces the vibrations generated by the engine and the movement of the vehicle to avoid damages in the chassis. Nowadays, the most used damper model is the hydraulic telescopic. This type of damper is a passive suspension system.

One of the main research lines of semiactive suspension systems is the magneto-rheological damper. These dampers have a magneto- rheological fluid which has a 40 % of metallic particles. When applying a magnetic field to the damper, these metallic particles align and produce a variation in the damper force. The advantages of these dampers are the low response time and the big amount of variation possibilities that they provide.

There are two models of magneto- rheological dampers: the direct model and the inverse model. The first one obtains the damper force by knowing the current that has to be applied to the damper. The inverse model estimates the current that has to be applied to the damper to get the desired force.

In this project a model for an inverse magneto- rheological damper is implemented by using Artificial Neural Networks. The software used is called JavaNNS. The structure of the Neural Network used has one input layer with four neurons (each neuron corresponds to an input variable: displacement, force, frequency and velocity), many hidden layers as it is needed and one output layer with one neuron which corresponds to the current. The results obtained show that a network of three hidden layers with 20 neurons is the optimal one to this model of magneto- rheological damper.

ÍNDICE

CAPÍTULO 1: INTRODUCCIÓN	1
1.1. INTRODUCCIÓN	1
1.2. OBJETIVO DEL PROYECTO	2
1.3. ESTRUCTURA DEL PROYECTO	2
 CAPÍTULO 2: SISTEMA DE SUSPENSIÓN DE UN VEHÍCULO AUTOMÓVIL	 4
2.1. INTRODUCCIÓN	4
2.2. ELEMENTOS DE LA SUSPENSIÓN	8
2.2.1. ELEMENTOS ELÁSTICOS	8
2.2.2. BARRA ESTABILIZADORA	13
2.2.3. <i>SILENTBLOCKS</i> Y COJINETES ELÁSTICOS	15
2.2.4. RÓTULAS	16
2.2.5. MANGUETA Y BUJE	17
2.2.6. TRAPÉCIOS O BRAZOS DE SUSPENSIÓN	17
2.2.7. TIRANTES DE SUSPENSIÓN	18
2.2.8. AMORTIGUADORES	18
 CAPÍTULO 3: TIPOS DE SISTEMAS DE SUSPENSIÓN	 27
3.1. INTRODUCCIÓN	27
3.1.1. SEGÚN LA GEOMETRÍA	27
A) SUSPENSIÓN RÍGIDA O DEPENDIENTE	27
B) SUSPENSIÓN SEMIRRÍGIDA	28
C) SUSPENSIÓN INDEPENDIENTE	30
3.1.2. SEGÚN EL SISTEMA DE CONTROL	33
A) SISTEMA DE SUSPENSIÓN PASIVA	34
B) SISTEMA DE SUSPENSIÓN ACTIVA	34
C) SUSPENSIÓN SEMIACTIVA	36

CAPÍTULO 4: FLUIDOS MAGNETO-REOLÓGICOS	37
4.1. INTRODUCCIÓN	37
4.2. MATERIALES INTELIGENTES	37
4.3. FLUIDOS MAGNETO-REOLÓGICOS	38
4.4. APLICACIONES FLUIDOS MAGNETO-REOLÓGICOS.....	40
4.5. AMORTIGUADORES MAGNETO-REOLÓGICOS	42
 CAPÍTULO 5: MODELOS DE AMORTIGUADORES MAGNETO-REOLÓGICOS	44
5.1. INTRODUCCIÓN	44
5.2. MODELOS PARAMÉTRICOS.....	45
5.2.1. MODELOS DIFERENCIALES	45
5.2.2. MODELOS ALGEBRAICOS.....	48
5.3. MODELOS NO PARAMÉTRICOS	50
5.3.1. MODELO INVERSO BASADO EN REDES NEURONALES.....	51
 CAPÍTULO 6: REDES NEURONALES ARTIFICIALES.....	52
6.1. INTRODUCCIÓN	52
6.2. RED NEURONAL ARTIFICIAL.....	53
6.2.1. PERCEPTON MULTICAPA.....	54
6.2.2. FUNCIÓN DE ENTRADA.....	55
6.2.3. FUNCIÓN DE ACTIVACIÓN	56
6.2.4. FUNCIÓN DE SALIDA	58
6.3. APRENDIZAJE DE UNA RED NEURONAL ARTIFICIAL	59
6.3.1. APRENDIZAJE SUPERVISADO.....	60
6.3.2. APRENDIZAJE NO SUPERVISADO	61
6.3.3. REGLA DE APRENDIZAJE <i>BACKPROPAGATION</i>	62
6.4. VALIDACIÓN DE UNA RNA	68
6.5. JAVANNS.....	68
6.6. APLICACIONES DE LAS RNA.....	69
 CAPÍTULO 7: RESULTADOS	70
7.1. INTRODUCCIÓN	70
7.2. PATRONES DE ENTRENAMIENTO Y VALIDACIÓN	71
7.3. TIPOLOGÍA DE LA RED NEURONAL	73
7.4. FUNCIÓN DE ACTIVACIÓN	74

7.5.	PESOS SINÁPTICOS.....	74
7.6.	FACTOR DE ENTRENAMIENTO.....	74
7.7.	GRÁFICA DE ERROR.....	75
7.8.	PROCESO DE APRENDIZAJE.....	75
7.8.1.	RED 4-10-1	75
7.8.2.	RED 4-20-1	79
7.8.3.	RED 4-30-1	82
7.8.4.	RED 4-20-20-1	85
7.8.5.	RED 4-30-30-1	87
7.8.6.	RED 4-25-25-25-1.....	89
CAPÍTULO 8: CONCLUSIONES Y TRABAJOS FUTUROS		91
8.1.	INTRODUCCIÓN	91
8.2.	CONCLUSIONES	91
8.3.	TRABAJOS FUTUROS	92
BIBLIOGRAFÍA.....		93
ANEXO A		98
TUTORIAL JAVANNS.....		98

ÍNDICE DE FIGURAS

CAPÍTULO 2: SISTEMA DE SUSPENSIÓN DE UN VEHÍCULO AUTOMÓVIL 4

Figura 2.1: Sistema de suspensión en un Opel Insignia SportsTourer	5
Figura 2.2: Tipos de oscilaciones en un vehículo	6
Figura 2.3: Oscilaciones en coches reales	6
Figura 2.4: Influencia de la dureza del muelle en las oscilaciones	7
Figura 2.5: Comportamiento subvirador (B) y sobrevirador (C) de un vehículo	8
Figura 2.6: Ballesta	9
Figura 2.7: Suspensión con ballestas.....	9
Figura 2.8: Montaje longitudinal de ballesta.....	10
Figura 2.9: Montaje transversal de ballesta.....	10
Figura 2.10: Muelle helicoidal en un sistema de suspensión	11
Figura 2.11: Posiciones de un muelle helicoidal	11
Figura 2.12: Suspensión con barra de torsión	12
Figura 2.13: Montaje de barra de torsión	12
Figura 2.14: Montaje longitudinal y transversal de barras de torsión	12
Figura 2.15: Montaje mixto de barras de torsión	13
Figura 2.16: Sistema de suspensión con barra estabilizadora	13
Figura 2.17: Comportamiento barra estabilizadora	14
Figura 2.18: Barra estabilizadora	14
Figura 2.19: <i>Silentblocks</i> de poliuretano	15
Figura 2.20: Posición del <i>silentblock</i> en el vehículo	15
Figura 2.21: Cojinetes elásticos	16
Figura 2.22: Rótulas	16
Figura 2.23: Mangueta y buje	17
Figura 2.24: Trapecios en el sistema de suspensión.....	17
Figura 2.25: Amortiguador de fricción.....	18
Figura 2.26: Amortiguador hidráulico telescópico actual	19
Figura 2.27: Componentes de un amortiguador hidráulico	20
Figura 2.28. Amortiguador hidráulico durante la expansión y compresión	21
Figura 2.29: Esquema amortiguador bitubo	22
Figura 2.30: Amortiguador bitubo no presurizado y presurizado	23
Figura 2.31: Esquema de amortiguador monotubo	24
Figura 2.32: Amortiguador a gas.....	26

CAPÍTULO 3: TIPOS DE SISTEMAS DE SUSPENSIÓN	27
Figura 3.1: Suspensión eje rígido.....	28
Figura 3.2: Comportamiento eje rígido ante un obstáculo	28
Figura 3.3: Suspensión con eje de Dion.....	29
Figura 3.4: Suspensión con eje torsional.....	30
Figura 3.5: Suspensión independiente de eje oscilante	31
Figura 3.6: Suspensión brazos tirados.....	31
Figura 3.7: Suspensión McPherson	32
Figura 3.8: Suspensión paralelo deformable	33
Figura 3.9: Suspensión multibrazo de un Audi A6	33
Figura 3.10: Suspensión pasiva.....	34
Figura 3.11: Suspensión activa.....	35
Figura 3.12: Suspensión semiactiva	36
 CAPÍTULO 4: FLUIDOS MAGNETO-REOLÓGICOS	 37
Figura 4.1: Alineación partículas metálicas	38
Figura 4.2: Características fluido reológico	39
Figura 4.3: Puente del Lago Dong Ting en China.....	40
Figura 4.4: Mano de robot.....	41
Figura 4.5: Prótesis de rodilla	41
Figura 4.6: Amortiguador magneto-reológico.....	42
Figura 4.7: Sistema MagneRide en un Audi TT Coupé.....	43
 CAPÍTULO 5: MODELOS DE AMORTIGUADORES MAGNETO-REOLÓGICOS	 44
Figura 5.1: Modelo de Bouc-Wen para amortiguador MR	45
Figura 5.2: Modelo de Bouc-Wen modificado para amortiguador MR	46
Figura 5.3: Modelo de Dahl modificado para un amortiguador MR.....	48
Figura 5.4: Modelo de Kwok para amortiguador MR.....	49
 CAPÍTULO 6: REDES NEURONALES ARTIFICIALES.....	 52
Figura 6.1: Neurona biológica y sus partes	54
Figura 6.2: Estructura de una RNA	55
Figura 6.3: Funcionamiento interno de una RNA	56
Figura 6.4: Gráfica y fórmula de la función de activación lineal	57
Figura 6.5: Gráfica y fórmula de la función de activación escalón.....	57

Figura 6.6: Gráfica y fórmula de la función de activación tangente hiperbólica	58
Figura 6.7: Gráfica y fórmula de la función de activación logística o sigmoideal.....	58
Figura 6.8: Red neuronal sencilla.....	62
Figura 6.9: Representación del error en una RNA	68

CAPÍTULO 7: RESULTADOS 70

Figura 7.1: Esquema de un modelo directo y un modelo inverso de un amortiguador MR....	70
Figura 7.2: Patrón de entrenamiento sin normalizar (izquierda) y normalizado (derecha)	72
Figura 7.3: Patrón de validación sin normalizar (izquierda) y normalizado (derecha)	72
Figura 7.4 Red 4-10-1 sin entrenar.....	76
Figura 7.5: Gráfica de error red 4-10-1 con función tangente hiperbólica.....	77
Figura 7.6: Ventana “log” red 4-10-1 función tangente hiperbólica	77
Figura 7.7 Gráfica de error red 4-10-1 con función sigmoideal	78
Figura 7.8: Red 4-20-1 sin entrenar	79
Figura 7.9: Gráfica de error red 4-20-1 con función tangente hiperbólica.....	80
Figura 7.10 Gráfica de error red 4-20-1 con función sigmoideal.....	81
Figura 7.11: Red 4-30-1 sin entrenar	82
Figura 7.12: Gráfica de error red 4-30-1 con función tangente hiperbólica.....	83
Figura 7.13 Gráfica de error red 4-30-1 con función sigmoideal.....	84
Figura 7.14: Red 4-20-20-1 sin entrenar	85
Figura 7.15: Gráfica de error red 4-20-20-1 con función sigmoideal	86
Figura 7.16: Red 4-30-30-1 sin entrenar	87
Figura 7.17: Gráfica de error red 4-30-30-1 con función sigmoideal	88
Figura 7.18: Red 4-25-25-25-1 sin entrenar.....	89
Figura 7.19: Gráfica de error red 4-25-25-25-1	90

ANEXO A: TUTORIAL JAVANNS 98

Figura A.1: Interfaz JavaNNS	99
Figura A.2: Crear capas de redes neuronales	99
Figura A.3: Red 4-5-1	100
Figura A.4: Red 6-10-10-10-3.....	100
Figura A.5: Conexiones entre neuronas	101
Figura A.6: Red 4-5-1 con conexiones.....	101
Figura A.7: Red 6-10-10-10-3 con conexiones.....	102
Figura A.8: Ejemplo patrón de entrenamiento y de validación.....	103

Figura A.9: Datos entrenamiento y validación reconocidos por el software.....	103
Figura A.10: Inicializar pesos en el panel de control.....	104
Figura A.11: Pestaña <i>patterns</i> del panel de control.....	104
Figura A.12: Pestaña <i>learning</i> del panel de control	105
Figura A.13: Gráfica de error de la red 4-5-1.....	106
Figura A.14: Gráficas de pesos	106
Figura A.15: Red 4-5-1 entrenada.....	107
Figura A.16: Documento de texto del archivo .res.....	107
Figura A.17: Ventana “log”	108

ÍNDICE DE TABLAS

CAPÍTULO 7: RESULTADOS	70
Tabla 7.1: Unidades de los datos recogidos	71
Tabla 7.2: Resumen de redes utilizadas	74
Tabla 7.3: Resumen funciones de activación de cada capa.....	74
Tabla 7.4: Red 4-10-1 tangente hiperbólica	78
Tabla 7.5: Red 4-10-1 sigmoidal.....	79
Tabla 7.6: Red 4-20-1 tangente hiperbólica	80
Tabla 7.7: Red 4-20-1 sigmoidal.....	81
Tabla 7.8: Red 4-30-1 tangente hiperbólica	83
Tabla 7.9: Red 4-30-1 sigmoidal.....	84
Tabla 7.10: Red 4-20-20-1 sigmoidal	87
Tabla 7.11: Red 4-30-30-1sigmoidal	88
Tabla 7.12: Red 4-25-25-25-1 sigmoidal	90

CAPÍTULO 1

INTRODUCCIÓN

1.1. INTRODUCCIÓN

El sistema de suspensión de un vehículo automóvil es el encargado de mantener las ruedas en contacto con el suelo, absorbiendo las vibraciones y las desigualdades del terreno y mejorando el confort de los pasajeros. Este sistema permite la marcha estable y segura durante la conducción. Uno de los principales elementos de la suspensión mecánica junto con los resortes o muelles y la barra estabilizadora son los amortiguadores.

Los amortiguadores son elementos resistentes que evitan la prolongación indefinida de las oscilaciones, es decir, frenan las vibraciones para que no causen daños en el vehículo. Se encargan de soportar las cargas que se producen durante el movimiento. Los amortiguadores más utilizados actualmente son los hidráulicos telescópicos. Este tipo de amortiguación es una amortiguación pasiva que, debido a su bajo coste, es la más común. Sin embargo, los estudios futuros pretenden conseguir un mayor compromiso de estabilidad-comodidad. Las suspensiones pasivas están diseñadas para conseguir unos resultados óptimos en determinadas situaciones solamente. Es por ello que se están realizando avances en los llamados sistemas inteligentes, los cuales, permiten la adaptación al terreno por el que se circula [7].

Una de las principales líneas de investigación de estos sistemas inteligentes son los amortiguadores magneto-reológicos (MR). Este es un caso de suspensión semiactiva formada por amortiguadores monotubos sin válvulas electromagnéticas. En vez de aceite, contienen un fluido magneto-reológico que está formado en un 40% por partículas metálicas. Al producir un campo magnético, estas partículas se magnetizan, alineándose y modificando la dureza del amortiguador. La principal ventaja de este sistema es la rapidez y la gran variedad de posibilidades de regulación que ofrece [21].

Este Trabajo de Fin de Grado se basa en el modelado de un amortiguador MR inverso. Como la mayoría de los sistemas de control semiactivos, este tipo de amortiguadores presentan

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

un comportamiento no lineal. Por lo que, la resolución de las ecuaciones diferenciales que simulan el comportamiento dinámico de éstos, es de alta complejidad matemática. Por este motivo se utilizan redes neuronales, como es en el caso de este proyecto en el que se utiliza el software JavaNNS [33].

1.2. OBJETIVO DEL PROYECTO

El principal objetivo de este Trabajo de Fin de Grado es el modelado inverso de un amortiguador MR basado en redes neuronales.

Existen dos modelos de amortiguadores MR: el modelo directo y el modelo inverso. El primero se basa en que a partir de una corriente que se le proporciona al sistema, éste sea capaz de producir la fuerza de amortiguación necesaria. En el segundo caso, el que se va a estudiar en este proyecto, el sistema estima la corriente con la que hay que alimentar el amortiguador MR para conseguir la fuerza deseada.

En este proyecto, a partir de unos datos de entrada conocidos que son el desplazamiento del amortiguador, la velocidad, la fuerza y la frecuencia se va a modelizar un amortiguador para conseguir una salida: la corriente. Para ello, se va a utilizar un programa de redes neuronales artificiales (JavaNNS en concreto).

1.3. ESTRUCTURA DEL PROYECTO

Este Trabajo de Fin de Grado está dividido en ocho capítulos y un anexo, siendo la presente introducción el primero de los capítulos.

En el segundo capítulo “La suspensión de un vehículo automóvil”, se describe brevemente la suspensión de un vehículo automóvil haciendo un mayor hincapié en el elemento amortiguador.

El tercer capítulo “Tipos de sistemas de suspensión” recoge dos posibles clasificaciones de la suspensión de un vehículo automóvil: según su geometría (rígida, semirrígida o independiente) y según el elemento de control (suspensión pasiva, activa o semiactiva).

El capítulo 4 “Fluidos magneto-reológicos” resume los conceptos básicos de los fluidos MR ya que son la base de este tipo de amortiguadores.

En el capítulo 5 “Tipos de modelos de amortiguadores magneto-reológicos” se explica detalladamente los modelos paramétricos y no paramétricos que existen de estos amortiguadores.

El sexto capítulo “Redes neuronales artificiales (JavaNNS)” explica todos los conceptos importantes para entender las redes neuronales artificiales (RNA) así como su funcionamiento. En concreto se explica el software utilizado JavaNNS.

En el capítulo 7, “Resultados”, se muestran los resultados obtenidos del modelo inverso de amortiguador MR basado en redes neuronales.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO- REOLÓGICO UTILIZANDO REDES NEURONALES

En el último capítulo, el capítulo 8, se indican las principales conclusiones obtenidas en el presente proyecto así como los posibles trabajos futuros a realizar.

El último capítulo del proyecto es un anexo que explica detalladamente el funcionamiento del software JavaNNS utilizado para el modelado del amortiguador MR inverso.

CAPÍTULO 2

SISTEMA DE SUSPENSIÓN DE UN VEHÍCULO AUTOMÓVIL

2.1. INTRODUCCIÓN

El sistema de suspensión de un vehículo automóvil tiene como objetivo principal absorber las irregularidades del terreno por el que se desplaza evitando que éstas dañen el vehículo. Además, debe encargarse de mantener las ruedas en contacto con el suelo y de ofrecer mayor comodidad y seguridad al viajero. Las pequeñas irregularidades pueden ser absorbidas por los propios neumáticos, mientras que las que son mayores deben hacerlo los elementos elásticos del sistema de suspensión así como los elementos amortiguadores.

Se considera sistema de suspensión a todo aquello que está entre los elementos no suspendidos (ejes y ruedas) y los elementos suspendidos (carrocería, bastidor, pasajeros y carga). La suspensión proporciona estabilidad y evita que la carrocería se incline demasiado al virar o la parte delantera al frenar [7].

Las oscilaciones y vibraciones que se producen durante la marcha del vehículo hacen más difícil su conducción y control. Por ello son necesarios los amortiguadores en el sistema de suspensión, para controlar y detener esas vibraciones, de otro modo, éstas seguirían indefinidamente poniendo en peligro la seguridad del usuario [1, 2].

En resumen, las diferentes funciones del sistema de suspensión de un vehículo automóvil son las siguientes:

- Absorber las irregularidades del terreno evitando dañar la carrocería y a los viajeros.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

- Mantener el control de dirección del vehículo, es decir, conseguir una correcta alineación de las ruedas en todo momento y mantener la adherencia de los neumáticos sobre la calzada.
- Sustener la carga del vehículo.
- Transmitir las fuerzas de aceleración y de frenada entre los ejes y el bastidor.
- Proporcionar la máxima estabilidad, seguridad y confort en el vehículo.

En la figura 2.1 se muestra el sistema de suspensión completo de un automóvil, en concreto, de un Opel Insignia SportsTourer.



Figura 2.1: Sistema de suspensión en un Opel Insignia SportsTourer [34]

Durante la marcha, se producen numerosas oscilaciones que se deben tanto al movimiento como a una mala conducción. También se pueden producir por el reparto desigual de las cargas o al efecto de fuerzas laterales. Estos movimientos u oscilaciones se producen en el centro de gravedad del vehículo y se distribuyen a lo largo de los diferentes ejes espaciales. Existen tres tipos principales de oscilaciones [16]:

- a) Empuje: es producido en el eje vertical del vehículo al pasar por un terreno ondulado.
- b) Cabeceo: se origina en el eje longitudinal debido a las frenadas bruscas.
- c) Bamboleo: se produce en el eje transversal al tomar curvas a alta velocidad.

En la figura 2.2 se muestran los tres tipos de movimientos u oscilaciones que se producen en el vehículo según el eje dónde se generan.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES




Figura 2.2: Tipos de oscilaciones en un vehículo [9, 16]

La figura 2.3 muestra tres figuras de diferentes coches de rally en los que se observan casos reales de los movimientos mencionados anteriormente. La primera figura representa un ejemplo de empuje, la segunda figura es un caso de cabeceo y la última, es un ejemplo de bamboleo o balanceo.



Empuje



Cabeceo



Bamboleo

Figura 2.3: Oscilaciones en coches reales [35]

Las vibraciones generadas durante el movimiento y, sobre todo, a altas velocidades son perjudiciales para los viajeros. Deben ser absorbidas por el sistema de suspensión como ya se ha

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

mencionado anteriormente. La dureza del muelle afecta a estas oscilaciones, un muelle blando tiene un gran recorrido y pocas oscilaciones bajo la carga, mientras que un muelle duro tiene un corto recorrido y numerosas vibraciones bajo la carga. La figura 2.4 muestra esta influencia de la dureza del muelle sobre las oscilaciones del vehículo.




Figura 2.4: Influencia de la dureza del muelle en las oscilaciones [9]

El ser humano puede aguantar bien frecuencias entre 1 Hz y 2 Hz pero las frecuencias elevadas pueden producir fatiga, dificultades respiratorias, dolor de cuello y vértebras o dolor de cabeza. Estos dolores y fatigas se deben a que diferentes partes del cuerpo entran en resonancia a determinadas frecuencias que deben evitarse. El asiento, junto con su suspensión, son elementos fundamentales en el confort de los viajeros ya que, para evitar la resonancia, sus muelles deben tener frecuencias naturales alejadas de las vibraciones transmitidas a la carrocería.

Es importante a la hora de diseñar un vehículo tener muy en cuenta el tipo de suspensión que se va a utilizar porque afecta directamente al confort y a la seguridad del conductor y los pasajeros. Una suspensión blanda contribuye a un mayor confort en el habitáculo, mientras que una suspensión dura favorece la adherencia de los neumáticos sobre el terreno. Por ello, a la hora de diseñar hay que tener en cuenta a qué prestaciones se les va a dar una mayor importancia para cada vehículo.

El tipo de suspensión de un vehículo afecta al comportamiento de éste, pudiendo hacer que el vehículo sea subvirador o sobrevirador al trazar una curva. En la figura 2.5 se muestran ambos comportamientos del vehículo así como el trazado estable de una curva. En la imagen A se ve el comportamiento estable del vehículo durante la curva. En la imagen B se muestra un comportamiento subvirador, es decir, el ángulo de giro del coche es menor que el que debería producir por la posición de las ruedas delanteras. En la imagen C se muestra el comportamiento sobrevirador, las ruedas traseras no siguen el mismo trazado que las ruedas delanteras y se deslizan hacia el exterior de la curva. Los riesgos principales de estos comportamientos son salirse de la calzada y los trompos, por ello, hay que controlar que no se produzcan en exceso [14].

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES




Figura 2.5: Comportamiento subvirador (B) y sobrevirador (C) de un vehículo [14]

2.2. ELEMENTOS DE LA SUSPENSIÓN

El sistema de suspensión debe estar formado por una parte elástica que absorba las desigualdades del terreno y por una parte amortiguadora que impida el balanceo excesivo de la carrocería. El conjunto elástico está formado por ballestas, muelles helicoidales y barras de torsión y el conjunto de amortiguación está formado por los amortiguadores. También consta de otros elementos constructivos como los *silentblocks*, los brazos o las rótulas y elementos que mejoran el comportamiento de la suspensión como las barras estabilizadoras [8].

2.2.1. ELEMENTOS ELÁSTICOS

Los elementos elásticos de la suspensión son los encargados de evitar que las irregularidades del terreno se transmitan como golpes a la carrocería mejorando el confort del vehículo y de mantener las ruedas en contacto con el suelo favoreciendo la estabilidad. Estos elementos son las ballestas, los muelles helicoidales y las barras de torsión.

- a) **Ballestas:** Están formadas por varias hojas de acero superpuestas cuya sección puede ser constante o variable y se unen mediante unas abrazaderas que permiten el desplazamiento de las láminas cuando se deforman por el peso que soportan. Las láminas trabajan de forma conjunta y pueden presentar comportamiento lineal o no. La hoja superior se llama “hoja maestra” y va curvada en sus extremos (ver figura 2.6) formando unos ojos en los que se colocan casquillos que sirven para unir la ballesta al bastidor por medio de pernos o bulones. Todas las hojas se unen en el centro mediante un tornillo pasante con tuerca. El número de hojas y su espesor depende de la carga que deban soportar.

En la figura 2.6 se muestra una ballesta con sus elementos principales: las hojas de acero (1), las abrazaderas (2), los ojos con los bulones (3) y el tornillo pasante (4) que sujeta por el centro todas las hojas de acero.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES




Figura 2.6: Ballesta [36]

La suspensión con ballestas es utilizada en vehículos con puente delantero y puente trasero. Las ballestas tienen una cierta curvatura para que, al circular sobre baches, se pongan rectas y alarguen su longitud. Por este motivo deben unirse al chasis mediante un sistema que permita su alargamiento. Este sistema se coloca en la parte posterior de la ballesta y consiste en una gemela que une la ballesta al chasis con un tornillo pasante. En el ojo de la ballesta (ver figura 2.6) se coloca el *silentblock* (ver sección 2.2.3).

En la figura 2.7 se observa una suspensión por ballesta. En la imagen de la izquierda se ve una ballesta instalada en la suspensión de un camión y en la de la derecha un sistema de suspensión completo con ballestas.



Figura 2.7: Suspensión con ballestas [43]

Existen dos tipos de montaje de ballestas, pueden montarse longitudinalmente a la marcha del vehículo o transversalmente.

- *Montaje longitudinal:* Se realiza montando la ballesta con un punto fijo en su parte delantera (según la marcha del vehículo) y con un punto móvil que permita los movimientos de la ballesta cuando se deforma con el bastidor. El enlace fijo se hace directamente uniendo la ballesta al soporte mientras que el enlace móvil se realiza utilizando una gemela (ver figura 2.8) entre el bastidor y la ballesta. Este tipo de montaje es el más utilizado en autocares y camiones.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

En la figura 2.8 se muestra un montaje longitudinal de una ballesta con el punto fijo y el punto móvil o gemela.




Figura 2.8: Montaje longitudinal de ballesta [9]

- *Montaje transversal:* Se realiza uniendo los extremos de la ballesta al puente o brazos de suspensión utilizando entre ellos elementos móviles como gemelas. La base de la ballesta se une a una traviesa del bastidor o carrocería. Este montaje es el más utilizado en turismos.

En la figura 2.9 se observa el montaje transversal de una ballesta con los brazos de suspensión y las gemelas.




Figura 2.9: Montaje transversal de ballesta [9]

- b) Muelles helicoidales: Están contruidos por una varilla de acero de entre 10 y 15 mm de diámetro normalmente y enrollados en forma de hélice o espiral. El diámetro del muelle depende de la carga que vaya a soportar. Sus espiras son planas tanto en la parte inferior como en la superior para conseguir mayor superficie de apoyo. La figura 2.10 muestra un resorte helicoidal en un sistema de suspensión.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES




Figura 2.10: Muelle helicoidal en un sistema de suspensión [10]

La flexibilidad del muelle depende del número de espiras, del diámetro de la varilla, del paso entre las espiras, del acero utilizado y del ángulo de inclinación de las espiras. Para que el efecto del muelle se mantenga, las espiras no deben tocarse. En la figura 2.11 se muestran las tres posiciones posibles del muelle. En primer lugar el muelle sin montar (estirado), después el muelle montado en el vehículo (a compresión) y, por último, el muelle montado en el vehículo con carga.




Figura 2.11: Posiciones de un muelle helicoidal [9]

- c) Barras de torsión: Los avances y los nuevos materiales han permitido sustituir los muelles helicoidales y las ballestas por barras de torsión. Las barras de torsión son resortes que se utilizan en vehículos con suspensión independiente. Su funcionamiento consiste en una varilla de acero elástico que está sujeta por uno de sus extremos y, mientras se le aplica en el otro extremo un esfuerzo de torsión, la barra se retuerce volviendo a su forma original al cesar dicho esfuerzo debido a sus propiedades elásticas. Al subir o bajar la varilla a causa de las desigualdades del terreno, se genera en ella un esfuerzo de torsión que al deformarse elásticamente produce el movimiento de la rueda. En la figura 2.12 de la izquierda se muestra un sistema de suspensión de un Renault Megane del eje trasero con barras de torsión y en la figura de la derecha un sistema de suspensión con barras de torsión de un Peugeot 508.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES




Figura 2.12: Suspensión con barra de torsión [10]

En cuanto a su montaje, las barras de torsión pueden montarse longitudinal o transversalmente al eje del bastidor (ver figura 2.14). Para colocarlas sobre el vehículo, hay que fijar uno de sus extremos al chasis o carrocería para que no pueda girar en su soporte. En el otro extremo se coloca una palanca o brazo solidario a la barra unida en su extremo libre al eje de la rueda. La figura 2.13 muestra el mecanismo de unión de la barra de torsión con el eje de la rueda a través del brazo y con la carrocería.



Figura 2.13: Montaje de barra de torsión [39]

Como se ha mencionado, el montaje de estas barras puede seguir dos direcciones con respecto al eje del bastidor pudiendo ser un montaje longitudinal o transversal, tal y como se muestra en la figura 2.14.




Figura 2.14: Montaje longitudinal y transversal de barras de torsión [9]

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

Además de los montajes mencionados anteriormente, se están utilizando unos diseños mixtos en vehículos con motor y tracción delanteros. En la figura 2.15 se muestra este diseño que consiste en un montaje longitudinal para el eje delantero y en una disposición transversal para la suspensión trasera.




Figura 2.15: Montaje mixto de barras de torsión [9]

2.2.2. BARRA ESTABILIZADORA

Las barras estabilizadoras o barras antibalanceo son el elemento más importante para dar estabilidad al vehículo al girar en una curva, ya que el balanceo en un coche al tomar las curvas puede alcanzar un valor muy alto poniendo en peligro el equilibrio dinámico de éste. Al girar, todo el peso del vehículo recae sobre las ruedas exteriores, provocando que la carrocería se incline hacia ese lado con el consecuente peligro de vuelco.

La figura 2.16 muestra un sistema de suspensión delantera con una barra estabilizadora que une ambas ruedas para controlar su estabilidad.




Figura 2.16: Sistema de suspensión con barra estabilizadora [44]

Las barras estabilizadoras consisten en unas barras de acero elástico con forma de U (ver figura 2.18). Pueden montarse tanto en el eje delantero como en el trasero, aunque es más común en el delantero. Van unidas en su parte central a la carrocería y ancladas por sus

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

extremos a los elementos de suspensión de cada lado del eje. Al tomar una curva, una de las ruedas tiende a subir y la otra a bajar, de esta manera se crea un par de torsión en la barra absorbiendo dicho esfuerzo. Es así como las barras estabilizadoras o antibalanceo mantienen la carrocería estable y evitan que ésta se incline demasiado hacia el lado exterior de la curva. Lo mismo ocurre cuando una de las ruedas encuentra un bache o un obstáculo, sin embargo, al circular en línea recta la acción de la barra es nula.

La figura 2.17 muestra el comportamiento de la barra estabilizadora en una curva o en una recta. En la primera imagen, no hay acción por parte de la barra ya que ambas ruedas oscilan a la vez en sentido vertical. En cambio, en la imagen de abajo se trata del caso de circular por una curva o de que las ruedas llevan recorridos diferentes por encontrarse un obstáculo. En el caso de la curva, la barra transfiere peso de la carrocería de la parte interior a la exterior de la curva y en el segundo caso, de una rueda a otra.




Figura 2.17: Comportamiento barra estabilizadora [10]

En la figura 2.18 se observa un ejemplo de barra estabilizadora con sus dimensiones principales, la longitud de la barra (L), el diámetro (d), la sección transversal (A) y la altura (x). El diseño de la barra puede cambiar pero éste es el más básico.




Figura 2.18: Barra estabilizadora [10]

Hay que tener en cuenta que si la barra es muy rígida puede incluso llegar a levantar la rueda interior. Si la barra está montada en un eje de tracción, la perderá en el caso de llegar a levantar la rueda y el balanceo alcanza un cierto valor.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

2.2.3. *SILENTBLOCKS* Y COJINETES ELÁSTICOS

Los *silentblocks* son elementos antivibratorios fabricados con un material flexible o elastómero (normalmente caucho) que sirven para absorber los choques y las vibraciones que se producen entre los componentes mecánicos y su estructura. El término anglosajón *silentblock* que, traducido literalmente al castellano, significa “bloque silencioso”, viene de la consecuencia directa de absorber los choques, es decir, elimina el ruido. En la figura 2.19 se muestran varios *silentblocks* fabricados con poliuretano [12].



Figura 2.19: *Silentblocks* de poliuretano [45]

La ubicación exacta del *silentblock* en el sistema de suspensión de un vehículo se encuentra en el brazo de suspensión, montado normalmente a compresión o cizalladura. En la figura 2.20 se observa la posición del *silentblock* en un vehículo marcado en rojo, el círculo azul señala la rótula (ver sección 2.2.4) del eje delantero. Es importante mantener en buen estado estos elementos porque si no se producen ruidos y desgaste de los neumáticos.



Figura 2.20: Posición del *silentblock* en el vehículo [45]

Los cojinetes elásticos, al igual que los *silentblocks* suelen estar fabricados con caucho. Permiten la unión de los componentes de la suspensión facilitando un pequeño desplazamiento. Se utilizan mucho en el montaje de las barras estabilizadoras y se suelen montar utilizando bridas o casquillos. En la figura 2.21 se muestran algunos cojinetes hechos de caucho.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES



Figura 2.21: Cojinetes elásticos [12]

2.2.4. RÓTULAS

Las rótulas son articulaciones con tres tipos de movimientos. Se encargan de la unión y fijación de la suspensión y la dirección, permitiendo su pivotamiento y giro, manteniendo la geometría de las ruedas. Están unidas a los brazos de suspensión permitiendo el giro de éstos en tres direcciones perpendiculares a los ejes. El ángulo de dos de estos giros está limitado mientras que el tercero tiene un ángulo de 360°.

La rótula tiene una semiesfera (ver figura 2.22) con un vástago cónico roscado por uno de sus extremos, la parte esférica está encerrada en un casquillo esférico y suele estar cubierta por una fina capa de material autolubricante. El casquillo está sujeto con tornillos a una parte de la mangueta (ver sección 2.2.5) y la parte cónica se une a los brazos de suspensión (ver sección 2.2.6). Es importante cambiarlas cuando sufren algún daño o alguna holgura. Como puede verse en la figura 2.22 existen diferentes tipos de rótulas según sea el modelo del vehículo.



Figura 2.22: Rótulas [13]

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

2.2.5. MANGUETA Y BUJE

La mangueta es una pieza que se encarga de la unión del buje (ver figura 2.23) y la rueda con los elementos de la suspensión como los trapecios, los amortiguadores o los tirantes. El material más utilizado para fabricar las manguetas es el acero aunque para los coches de competición se utilizan aleaciones. La mangueta debe diseñarse teniendo en cuenta las dimensiones y el diseño del vehículo. En el interior del buje se encuentran los rodamientos que permiten el giro de la rueda. La figura 2.23 muestra la unión de la mangueta con el buje y con el disco de freno, además de los rodamientos en el interior del buje.




Figura 2.23: Mangueta y buje [13]

2.2.6. TRAPÉCIOS O BRAZOS DE SUSPENSIÓN

Los trapecios son brazos articulados que soportan al vehículo mediante la suspensión. Se encargan de unir la mangueta y el buje al vehículo mediante los *silentblocks* como elementos elásticos y rótulas como elementos de guiado soportando los esfuerzos que se generan. Normalmente están fabricados en fundición o en chapa de acero embutida.

La figura 2.24 muestra el sistema de suspensión dónde se observan los trapecios superior e inferior.




Figura 2.24: Trapecios en el sistema de suspensión [39]

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

2.2.7. TIRANTES DE SUSPENSIÓN

Los tirantes de suspensión son brazos de acero longitudinales o transversales situados entre la carrocería y la mangueta o trapecio sujetándolos y guiándolos. También permiten la absorción de los desplazamientos y esfuerzos a través de los *silentblocks* y los cojinetes que se encuentran montados en sus extremos.

2.2.8. AMORTIGUADORES

Los amortiguadores se encargan de absorber las vibraciones generadas por elementos elásticos (muelles, barras de torsión y las ballestas) disipando la energía producida en forma de calor generalmente. El sistema de amortiguación es necesario en el sistema de suspensión para evitar las oscilaciones no deseadas y que no se transmitan a la carrocería. Además, los amortiguadores ayudan a mantener las ruedas en contacto con el suelo [11].

Al pasar por un obstáculo o un bache, los muelles se comprimen y estiran recogiendo la energía de la oscilación, al no tener capacidad de absorción, esta energía se transmite a la carrocería en forma de rebote. Este rebote en forma de vibración es el que debe ser absorbido por el amortiguador, recogiendo primero la compresión del muelle y luego la extensión, actuando como freno en dos sentidos. Es necesario el elemento amortiguador que frene estas vibraciones, sino, la oscilación se transmitiría a la carrocería indefinidamente.

Los amortiguadores pueden ser fijos o regulables, los primeros tienen siempre la misma dureza de amortiguación mientras que los regulables pueden adaptarse al terreno regulando la dureza. Entre estos últimos se encuentran los amortiguadores magneto-reológicos (MR).

Los primeros amortiguadores que se utilizaron en 1898 fueron los amortiguadores de fricción. Estos amortiguadores consisten en dos brazos unidos mediante un tornillo y con un disco de fricción entre ellos (ver figura 2.25). Uno de los brazos se acopla al mecanismo de la rueda y el otro a la carrocería. Para controlar la resistencia por fricción simplemente se aprieta más o menos el tornillo. La figura 2.25 muestra un amortiguador de fricción con todos sus componentes.



Figura 2.25: Amortiguador de fricción [11]

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

Los amortiguadores de fricción tienen la ventaja de ser muy sencillos, tanto en estructura como en modo de uso pero también presentan varios inconvenientes:

- Si no se supera la fuerza de fricción, la suspensión se bloquea y el vehículo queda sin suspensión.
- Si se supera la fuerza de fricción, la fuerza amortiguadora disminuye al aumentar la velocidad, lo cual no es deseable.
- Al desgastarse, su comportamiento se altera.
- Es necesaria la revisión periódica para cambiar las piezas desgastadas.

Por todos estos motivos, el amortiguador de fricción ya no se usa prácticamente y ha sido sustituido por los amortiguadores hidráulicos.

TIPOS DE AMORTIGUADORES

Los amortiguadores se clasifican en amortiguadores hidráulicos y en amortiguadores de gas. Además, los amortiguadores pueden ser de doble efecto o de simple efecto. Los de doble efecto son los más utilizados ya que amortiguan en dos sentidos, tanto a compresión como a expansión. En cambio, los de simple efecto solamente amortiguan en un sentido, o expansión o compresión pero no los dos a la vez [14].

- a) Amortiguadores hidráulicos: Son los más utilizados en la actualidad, en concreto, los hidráulicos telescópicos. Estos amortiguadores constan de un cilindro en el que hay aceite y dentro del cual trabaja un pistón. Este pistón tiene una serie de orificios y válvulas precomprimidas que permiten el paso del aceite de una zona a otra del pistón cuando se supera un cierto valor de la presión. En la figura 2.26 se muestra un amortiguador hidráulico telescópico actual.



Figura 2.26: Amortiguador hidráulico telescópico actual [14]

El principio de funcionamiento de estos amortiguadores es la transformación de energía cinética en energía térmica. Para ello, el aceite debe pasar a través de los orificios y de las válvulas del pistón. Cuando se comprime pasa de la cámara inferior a la superior del

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

cilindro hidráulico y cuando se expande de la superior a la inferior (ver figura 2.27). La resistencia hidráulica en el movimiento del pistón es la que determina la dureza de amortiguación.

La figura 2.27 muestra los componentes de los amortiguadores hidráulicos telescópicos. Están compuestos por un cilindro (A) dentro del cual se desliza un émbolo (B) que está unido a un vástago (C). La parte final del vástago es un anillo soporte (D) que se une al bastidor. Alrededor del cilindro (A) se coloca uno exterior y concéntrico (F) a éste. Ambos cilindros se encuentran sellados en su parte superior por la empaquetadura (E) a través de la cual pasa el vástago (C), al que también está unida la campana (G) encargada de preservar de polvo el amortiguador. El cilindro exterior (F) está unido al anillo (H) que se une al eje de la rueda y se comunica al cilindro (A) a través del orificio (I). El pistón (B) divide al cilindro (A) en dos cámaras (superior e inferior) por medio de los orificios calibrados (J y K). El orificio (K) se tapona mediante una válvula de bola (L).




Figura 2.27: Componentes de un amortiguador hidráulico [39]

De esta manera, el amortiguador queda dividido en tres cámaras; superior (1), inferior (2) y de compensación (3) las cuales están llenas de aceite. Cuando la rueda se mueve con respecto al chasis, también lo hace el anillo (H) y los cilindros (A y F) haciendo que se comprima el líquido contenido en la cámara (2) y pasando a través de los orificios (J y K) hacia la cámara (1). En esta cámara (1) se queda un espacio vacío a causa del movimiento ascendente de ambos cilindros (A y F). Por otro lado, una parte del líquido pasa de la cámara (2) a la de compensación (3) por el orificio (I), lo que hace que se frene el movimiento ascendente de los cilindros y consiguiendo la amortiguación de la suspensión.

Una vez superado el obstáculo que levantó la rueda, se produce la acción de la ballesta o el muelle, por lo que el anillo (H) desciende con la rueda al igual que los

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

cilindros (A y F). El líquido contenido en la cámara (1) se va comprimiendo por el pistón y pasa a la cámara (2) por el orificio (J). Por (K) no puede pasar ya que tiene una válvula antirretorno (L), actuando como freno de la ballesta o el muelle. La cámara (2) se va llenando con el aceite procedente de las otras cámaras a medida que los cilindros (A y F) descienden. En este amortiguador la fuerza de frenado es mayor en la expansión que en la compresión del muelle o ballesta, permitiendo que la rueda suba fácilmente y actúen el muelle o la ballesta pero evitando el rebote de éstos ya que sino aumentarían el número de oscilaciones.

La mayor o menor fuerza de frenado en los dos sentidos depende del calibre del orificio (J), mientras que la acción de frenado cuando la rueda sube depende del calibre del orificio (K). Al subir la rueda, el aceite de la cámara (2) no puede pasar a la (1) en su totalidad porque ésta es más pequeña a causa del vástago (C). Por ello existe la cámara de compensación (3), para que el líquido sobrante de la cámara (2) pase a la cámara (3). En cambio, cuando la rueda baja, pasa lo contrario, el líquido de la cámara (1) no es suficiente para llenar la (2) y es necesario utilizar el que hay en la cámara (3).

Este amortiguador es de doble efecto, amortigua tanto en expansión como en compresión. Sin embargo, cuando la rueda sube, la acción de freno del amortiguador es muy pequeña, siendo el doble aproximadamente cuando baja. Por eso, al subir la rueda es la ballesta o el muelle el que se deforma para absorber la desigualdad del terreno y, cuando baja, es el amortiguador el que frena las oscilaciones. La figura 2.28 muestra un amortiguador durante la compresión y la expansión del muelle.




Figura 2.28. Amortiguador hidráulico durante la expansión y compresión [7]

La energía generada durante la expansión y la compresión del muelle es recogida por el amortiguador y utilizada para comprimir el líquido que hay en su interior. Esta energía en forma de calor es absorbida por el líquido. La temperatura ambiente y el calor absorbido por el aceite afectan a la viscosidad del líquido, haciendo que éste atraviese mejor o peor las válvulas que separan las cámaras, haciendo que la suspensión sea más o

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

menos rígida. Esto tiene como consecuencia que, en invierno, en los primeros momentos de funcionamiento, la suspensión sea más dura porque el aceite con el frío se encuentra más denso. En cambio, en verano, el aceite está más fluido y la suspensión es más blanda.

Los amortiguadores hidráulicos son baratos pero su duración es limitada, presentan grandes pérdidas de eficacia ante el trabajo excesivo debido al aumento de temperatura, por eso no se utilizan en conducción deportiva ni en competición.

Existen dos tipos de amortiguadores hidráulicos telescópicos utilizados en la actualidad, pueden ser de doble tubo/bitubo o de un solo tubo/monotubo.

- *Amortiguadores de doble tubo o bitubo:* Son los más comunes. Existen dos tipos: no presurizados (aceite) y presurizados (aceite y gas). Están compuestos por dos cámaras, una interior y una de reserva y tienen válvulas en el pistón y en la base del amortiguador, llamada válvula de pie. En la figura 2.29 se observa un esquema de un amortiguador bitubo con sus principales componentes.




Figura 2.29: Esquema amortiguador bitubo [14]

El funcionamiento de los presurizados y de los no presurizados es prácticamente el mismo. La figura 2.30 muestra estos dos tipos de amortiguadores con sus componentes principales. A la izquierda se observa un amortiguador bitubo no presurizado y a la derecha uno presurizado. Los principales componentes de estos amortiguadores son: tubo y cámara exterior o de reserva, tubo y cámara interior o cilindro, pistón, vástago, válvula de pie, guía del vástago y acoplamientos superior e inferior.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES




Figura 2.30: Amortiguador bitubo no presurizado y presurizado [14]

El funcionamiento de estos amortiguadores debe explicarse por separado cuando se encuentra en la carrera de compresión y cuando se encuentra en la carrera de expansión.

- **Carrera de compresión:** Al penetrar el vástago, el aceite de la cámara interior fluye sin resistencia por todos los orificios y a través de la válvula antirretorno hacia el espacio existente al otro lado del pistón. De manera simultánea, una cantidad de aceite se ve desplazada por el volumen que el vástago va ocupando en la cámara interior. Este aceite se ve forzado a pasar por la válvula de pie en dirección a la cámara de reserva, la cual está llena de aire a presión atmosférica o de nitrógeno entre 4 y 8 bares. La fuerza de amortiguamiento depende de la resistencia impuesta por la válvula de pie al paso del aceite.
- **Carrera de extensión:** En el momento que se tira del vástago hacia fuera, el aceite que queda por encima del pistón se comprime y pasa por las válvulas que hay en él. Al igual que en la carrera de compresión, la resistencia del aceite al pasar por las válvulas determina la fuerza de amortiguamiento. El aceite que había llegado a la cámara de reserva vuelve sin encontrar resistencia a través de la válvula de pie hacia la cámara interior para compensar el volumen liberado por el vástago.

NO PRESURIZADOS: Tienen el inconveniente de que se pueden formar bolsas de aire bajo el vástago en las siguientes situaciones:

1. Transporte o almacenaje en horizontal del amortiguador antes de ser instalado.
2. Al estar el vehículo quieto durante un tiempo, la columna de aire o aceite de la cámara principal cae por gravedad.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

3. El aceite se contrae debido a su enfriamiento al final del viaje y se succiona aire hacia la cámara principal.

PRESURIZADOS: Es la disposición más utilizada para mejorar las prestaciones de los amortiguadores bitubo convencionales. Para ello, se añade una cámara de gas de baja presión, en torno a los 4 bares es suficiente ya que la fuerza amortiguadora en compresión la proporciona la válvula de pie. De esta manera la fuerza de extensión realizada por el amortiguador es baja, lo que permite utilizar esta solución en suspensiones McPherson que requiere diámetros de amortiguador elevados. Tienen varias ventajas con respecto a los no presurizados:

1. Mejor confort en la marcha.
2. Respuesta de la válvula más sensible para pequeñas amplitudes.
3. Reducción de ruido hidráulico.
4. Se mantienen operativos a pesar de la pérdida de gas.
5. Mejores condiciones de amortiguación en condiciones extremas.

En cuanto a los amortiguadores monotubo, los de doble tubo presurizados tienen la ventaja de tener menor longitud y menor fricción a iguales condiciones de operación.

- *Amortiguadores monotubo:* Aparecieron más tarde que los bitubo y cada vez se utilizan más en competición y en vehículos de altas prestaciones. Están constituidos principalmente por dos cámaras: una contiene el aceite y la otra el gas a presión (normalmente nitrógeno), separadas por un pistón flotante. En este caso sólo hay válvulas en el pistón. En la figura 2.31 se muestra un amortiguador monotubo con sus principales componentes.




Figura 2.31: Esquema de amortiguador monotubo [14]

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

Al igual que en los amortiguadores bitubo, para explicar su funcionamiento es necesario explicar por separado la carrera de compresión y la de extensión.

- **Carrera de compresión:** Al contrario que el amortiguador bitubo, el monotubo no tiene cámara de reserva. Para evitar el problema de ubicar el aceite que ocupa el espacio alrededor del vástago se coloca una cámara de volumen variable. Con el pistón flotante se divide la cámara interior en dos zonas: una la del aceite y otra la de gas presurizado (entre 20 y 30 bares). Al empujar el vástago hacia dentro, la zona del gas se comprime aumentando la presión en ambas zonas debido a la presión que ejerce el aceite sobre el pistón. El aceite se ve obligado a pasar por las válvulas del pistón. La fuerza de amortiguación queda determinada por la resistencia del aceite al pasar por estas válvulas.
- **Carrera de extensión:** Al tirar del vástago hacia fuera, el aceite por encima del pistón se comprime y pasa a través de las válvulas. La fuerza de amortiguación depende de la resistencia al pasar por dichas válvulas. Debido a la disminución de la presión en la cámara, el pistón flotante vuelve hacia arriba para recuperar su posición inicial y así compensar el volumen liberado por el vástago.

Los amortiguadores monotubo tienen algunas ventajas con respecto a los bitubo no presurizados:

1. Mayor diámetro de pistón a igual diámetro de carcasa, permitiendo la reducción de las presiones de operación.
2. Buena refrigeración, ya que la cámara está en contacto directo con el aire. Esto supone una mejor eficacia porque los amortiguadores transforman energía cinética en calorífica.
3. El nivel del aceite no baja al estar el vehículo estacionado.
4. Debido al pistón separador no queda restringida la posición de montaje y se pueden colocar incluso tumbados.
5. El aceite no forma espuma debido a la presurización, esto permite un buen amortiguamiento incluso con pequeñas amortiguaciones de alta frecuencia y además evita la cavitación.

También existen algunas desventajas:

1. Válvulas más complejas.
2. Mayor necesidad de espacio, lo que puede suponer una longitud de 100 mm en aplicaciones automótiles.
3. Mayores costes, pues se necesita una mayor precisión, tolerancias de fabricación y estanqueidad del gas.
4. La fuerza de extensión en su posición nominal es una desventaja debido a la presión interna del gas y a la diferencia de áreas efectivas a ambos

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

lados de pistón. Esta fuerza puede producir variaciones en la altura de amortiguación que debe ser considerada en el diseño.

- b) Amortiguadores a gas: Este tipo de amortiguadores sigue el mismo principio de funcionamiento que los amortiguadores hidráulicos pero contienen en uno de sus extremos nitrógeno a alta presión (24 bares). Para evitar que se mezclen el aceite y el gas, están separados por un pistón flotante. Con el desplazamiento del vástago, el aceite comprime el gas produciendo en éste una variación de volumen que da lugar a una respuesta instantánea y a un funcionamiento silencioso. Los amortiguadores a gas también actúan a modo de resorte elástico, por lo que vuelven a su posición cuando se deja de actuar sobre ellos. Este tipo de amortiguadores se observa en la figura 2.32.




Figura 2.32: Amortiguador a gas [9]

Los amortiguadores a gas pueden ser regulables o no regulables:

- *Regulables*: Se trata de amortiguadores monotubo que pueden o no tener botella exterior. Es un amortiguador de alta tecnología, muy caro pero proporcional a su alta eficacia por lo que es el más utilizado en la conducción deportiva y en los vehículos de competición y altas prestaciones.
- *No regulables*: Pueden ser amortiguadores monotubo o bitubo, de alta duración, muy resistentes a los golpes y a la alta temperatura en las condiciones de trabajo. Es un tipo de amortiguador de alta calidad y de elevado coste. El precio se ve compensado por su durabilidad y fiabilidad. Se utiliza sobre todo en vehículos de altas prestaciones.

CAPÍTULO 3

TIPOS DE SISTEMAS DE SUSPENSIÓN

3.1. INTRODUCCIÓN

Existen diferentes maneras de clasificar los sistemas de suspensión de los vehículos automóviles. Pueden clasificarse según la geometría, según los elementos de la suspensión o según el sistema de control, entre otros. En este capítulo se trata en primer lugar la clasificación según la geometría y, en segundo lugar, la clasificación según el sistema de control [15, 16, 17, 18].

3.1.1. SEGÚN LA GEOMETRÍA

Esta primera clasificación del sistema de suspensión de un vehículo se basa en la disposición de los elementos y la manera de montaje de los mismos. Dentro de esta clasificación se encuentran tres grandes grupos: la suspensión rígida o dependiente, la suspensión semirrígida y la suspensión independiente.

A) SUSPENSIÓN RÍGIDA O DEPENDIENTE

La suspensión rígida o dependiente consta de un eje rígido en el cual se montan las ruedas, unos resortes o muelles helicoidales a cada extremo y los amortiguadores. La gran ventaja de este sistema es que, debido a la escasez de partes móviles, tienen una larga vida de servicio. Además cabe destacar su robustez y sencillez de diseño al constar de muy pocas piezas y, por lo tanto, su bajo coste. Por este motivo, es muy utilizada en autobuses y vehículos de trabajo como camionetas y camiones. En la figura 3.1 se muestra una suspensión rígida en la que se observa el eje rígido que une las ruedas, las ballestas a cada extremo del eje y los amortiguadores.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES




Figura 3.1: Suspensión eje rígido [17]

Todo el sistema forma un conjunto y, como consecuencia, todo el movimiento de una rueda se transmite a la otra del mismo eje, como el eje va fijado directamente al bastidor, la inclinación se transmite a la carrocería. Por lo tanto, al pasar por un obstáculo, se pierde la posición horizontal del vehículo provocando un menor confort para los pasajeros y la pérdida de seguridad. Por este motivo no se utiliza actualmente para turismos. Este movimiento del eje en conjunto con las ruedas se observa en la figura 3.2.




Figura 3.2: Comportamiento eje rígido ante un obstáculo [16]

B) SUSPENSIÓN SEMIRRÍGIDA

Este tipo de suspensión es muy parecida a la suspensión de eje rígido pero, en este caso, las oscilaciones del terreno se transmiten sólo parcialmente de una rueda a otra. Es una geometría intermedia entre la suspensión rígida y la suspensión independiente. Existen dos tipos principales de suspensión semirrígida, la suspensión con eje de Dion y la suspensión con eje torsional.

- *Suspensión con eje de Dion*: Se trata de una suspensión semirrígida en la que las ruedas se unen con soportes articulados al grupo diferencial (ver figura 3.3). En este tipo de

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

suspensión, el diferencial forma parte de la masa suspendida ya que va anclado al bastidor. El giro se transmite a las ruedas a través de dos semiejes como en las suspensiones independientes. A la vez, ambas ruedas están unidas entre sí mediante un tubo de Dion permitiendo los deslizamientos longitudinales. Además, consta de muelles helicoidales y de brazos que limitan estos desplazamientos.

La principal ventaja de este sistema frente al eje rígido es la disminución del peso de la masa no suspendida a causa del poco peso del eje de Dion y del anclaje del grupo diferencial al bastidor ya que mantiene los parámetros de la rueda prácticamente constantes. Sin embargo, en la actualidad ya no se utiliza demasiado la suspensión con eje de Dion debido a su elevado coste.

En la figura 3.3 se muestra un esquema de un eje de Dion en la suspensión de un vehículo. En la parte inferior de la figura se explica el funcionamiento de este sistema cuando atraviesa un obstáculo.




Figura 3.3: Suspensión con eje de Dion [16]

- *Suspensión eje torsional*: Es un tipo de suspensión semirrígida que se utiliza en el eje trasero de los vehículos con tracción delantera. El tubo que une ambas ruedas tiene forma de U y se deforma ligeramente cuando una rueda atraviesa un obstáculo para volver a su posición inicial una vez superado. Las ruedas están unidas rígidamente a dos brazos longitudinales que están unidos a un travesaño que se retuerce y da estabilidad al vehículo. En la figura 3.4 se muestra este tipo de suspensión.

Gracias a esta configuración y a la torsión del puente, se recupera parcialmente el ángulo de caída que influye mucho en la estabilidad. Por este motivo, así como su bajo coste, peso y el poco espacio que ocupa, ésta es la suspensión más utilizada en vehículos de gama media-baja.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES



Figura 3.4: Suspensión con eje torsional [10]

C) SUSPENSIÓN INDEPENDIENTE

La suspensión independiente es la más utilizada en la actualidad. Este tipo de suspensión es la más óptima en cuanto a estabilidad y confort del vehículo ya que absorbe las irregularidades del terreno de forma independiente para cada rueda, sin transmitir los movimientos de una rueda a otra del mismo eje como ocurre en otras suspensiones. Otra gran ventaja de esta suspensión es que tiene muy poco peso suspendido, transmitiendo pocas oscilaciones al chasis. Para conseguir una dirección segura del vehículo, se debe garantizar que las variaciones de caída de rueda y ancho de rueda en las ruedas directrices son pequeñas. Hay que tener en cuenta que este tipo de suspensión es la única que se utiliza actualmente para las ruedas directrices, aunque puede presentar problemas para cargas elevadas.

Existen diferentes tipos de suspensiones independientes, pero las más importantes son: suspensión de eje oscilante, suspensión de brazos tirados, suspensión McPherson, suspensión de paralelo deformable y suspensión multibrazo (multilink).

- *Suspensión de eje oscilante*: Este sistema de suspensión tiene la característica de que las ruedas son solidarias a los semiejes excepto durante el giro de éstas, de tal forma que todo el conjunto se mueve alrededor de una articulación como puede verse en la figura 3.5. Sin embargo, este tipo de suspensión no puede utilizarse en el eje directriz ya que la caída de las ruedas es muy grande en las curvas debido al movimiento oscilatorio de los semiejes. Los otros elementos de este sistema son los muelles y los amortiguadores.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES




Figura 3.5: Suspensión independiente de eje oscilante [9]

- *Suspensión de brazos tirados*: La principal característica de esta suspensión son dos elementos soporte o brazos colocados longitudinalmente y unidos por un extremo al bastidor y por otro a la mangueta de la rueda. Si el eje es de tracción, el grupo diferencial va anclado al bastidor. El funcionamiento se basa en que las ruedas son tiradas o arrastradas por los brazos que pivotan alrededor del eje de anclaje de la carrocería. Existen numerosas variantes de este sistema, cuya diferencia es básicamente cuál es el eje de giro del brazo anclado al bastidor y qué elemento elástico utiliza (barras de torsión o muelles).

En la figura 3.6 se muestran dos variantes de este sistema. En la imagen de la izquierda se muestra un sistema de brazo semi-arrastrado en el cual los brazos pivotan sobre ejes que tienen componentes longitudinales, es decir, ejes oblicuos al plano longitudinal del vehículo. La ventaja de este sistema es que no necesita de estabilizadores longitudinales. En este caso, las variaciones de la vía dependen del ángulo de inclinación y de la posición de los brazos, lo que proporciona una mayor estabilidad. En cuanto a la figura de la derecha, se trata de un sistema de brazos arrastrados, los brazos pivotan sobre un eje de giro perpendicular al plano longitudinal del vehículo. Este tipo de sistema no produce prácticamente variaciones de vía, caída o avance de rueda.




Figura 3.6: Suspensión brazos tirados [37]

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

- *Suspensión McPherson*: Fue creada por el ingeniero de Ford Earle S. McPherson. Este sistema de suspensión se utiliza en ambos ejes, aunque sobre todo para el eje delantero. En la suspensión McPherson, las ruedas son controladas por un brazo oscilante triangular bajo el centro de gravedad de la rueda, un montaje de suspensión y una varilla de guía. Los brazos oscilantes se encuentran unidos al bastidor por dos soportes de goma-metal. La figura 3.7 muestra una suspensión McPherson.



Figura 3.7: Suspensión McPherson [38]

Su gran difusión se debe a su bajo coste, su sencillez de fabricación y mantenimiento y el poco espacio que ocupa. Sin embargo, es necesario que la carrocería tenga una mayor resistencia en los puntos donde se fijan los amortiguadores y muelles. La separación funcional de las ruedas del eje delantero y trasero permite alcanzar una gran agilidad y seguridad, así como un confort de marcha óptimo. Además, la suspensión McPherson tiene muy poca masa suspendida, una gran base de apoyo, fuerzas reducidas y un diseño más compacto que otras suspensiones.

- *Suspensión de paralelo deformable*: Este tipo de suspensión es, junto a la suspensión McPherson, la más utilizada tanto para el tren delantero como para el tren trasero. La unión entre la rueda y la carrocería son elementos transversales en diferentes planos. Su nombre se debe a que hay dos elementos superpuestos (ver figura 3.8) que asemejan a un paralelogramo. El movimiento de la rueda con respecto a la carrocería provoca que este paralelogramo se deforme. Hay diferentes diseños de paralelogramo deformable, siendo unos más complejos que otros.

En la figura 3.8 se muestra una configuración de paralelo deformable. Esta configuración es muy típica en los coches de Fórmula 1.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES



Figura 3.8: Suspensión paralelo deformable [38]

- *Suspensión “multilink” o multibrazo:* Las suspensiones multibrazo o *multilink* surgen a partir de las suspensiones de paralelo deformable: un par de brazos transversales, la mangueta de la rueda y el bastidor. La principal diferencia reside en que los elementos guía de este tipo de suspensión pueden tener anclajes elásticos mediante manguitos de goma, consiguiendo una mayor estabilidad y confort del vehículo. Para que una suspensión se considere multibrazo debe haber por lo menos tres brazos.

En la figura 3.9 se muestra una suspensión delantera de cuatro brazos de un Audi A6.



Figura 3.9: Suspensión multibrazo de un Audi A6 [38]

3.1.2. SEGÚN EL SISTEMA DE CONTROL

Otra manera de clasificar los sistemas de suspensión está basada en el sistema de control que se utilice. Dentro de esta clasificación se encuentran los sistemas de suspensión pasiva, activa y semiactiva.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

Los primeros sistemas utilizados fueron los sistemas de suspensión pasiva, los cuales están formados por elementos pasivos y están diseñados para trabajar de manera óptima pero solamente en condiciones concretas. A continuación surgieron los sistemas de suspensión activa, los cuales sustituyen los elementos no regulables de la suspensión pasiva por elementos con control eléctrico. El principal problema de estos sistemas es que, a pesar de conseguir una mayor adaptabilidad al terreno por el que circulan, suponen un alto coste y un gran gasto energético. Como sistema intermedio, surgieron los sistemas de suspensión semiactiva. Estos sistemas modifican elementos de la suspensión como pueden ser los resortes y los amortiguadores para conseguir adaptarse al terreno por el que se circula. Los amortiguadores MR forman parte de éstos últimos.

A) SISTEMA DE SUSPENSIÓN PASIVA

Los sistemas de suspensión pasiva son aquellos que están diseñados para trabajar de manera óptima pero solamente en condiciones específicas, no se adaptan al terreno por el que circulan. Estas suspensiones son las estudiadas en el apartado 3.1.1. Lo ideal para conseguir una mejor suspensión, con la mayor seguridad y confort posibles, es que la amortiguación sea regulable, para poder adaptarse al terreno. El problema de las suspensiones pasivas es que no consiguen un equilibrio óptimo entre confort y seguridad. Para conseguir un mejor confort es necesario colocar una suspensión blanda y para conseguir una mayor seguridad manteniendo el contacto de las ruedas con el terreno, se necesita una suspensión dura, por lo tanto, es muy difícil conseguir un resultado adecuado. Sin embargo, las suspensiones pasivas siguen siendo hoy en día las más utilizadas para vehículos pequeños y medios debido a su bajo coste.

En la figura 3.10 se muestra un esquema simplificado de la suspensión pasiva de un vehículo automóvil en el que se observan sus principales elementos: resortes o muelles de la suspensión (4) y el amortiguador (5).




Figura 3.10: Suspensión pasiva [9]

B) SISTEMA DE SUSPENSIÓN ACTIVA

Los sistemas de suspensión activa surgieron como necesidad de encontrar un mayor compromiso seguridad-confort en los vehículos. La suspensión activa es aquella capaz de adaptarse al terreno por el que se circula. Es una suspensión regulable sin muelles o amortiguadores, que actúa rápida y eficazmente sobre cada rueda.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

C) SUSPENSIÓN SEMIACTIVA

La suspensión semiactiva regula los elementos de la suspensión tradicional a través de actuadores para conseguir un mayor compromiso estabilidad-confort al adaptarse al terreno por el que circula.

En la mayoría de los sistemas de suspensión semiactiva el elemento de la suspensión que se controla es el amortiguador. Inicialmente, estos sistemas estaban basados en amortiguadores con electroválvulas, las cuales se controlan a través de una centralita electrónica a la que llega la información de una serie de sensores. Estos sensores miden variables como la posición, la velocidad de giro del volante, las diferentes aceleraciones del vehículo o la velocidad de éste para enviar esta información a la centralita y que se produzca el cambio de rigidez del amortiguador. Esta variación de rigidez puede hacerse manualmente cuando existen diferentes grados de dureza o automáticamente si la regulación se realiza de manera continua.

Para regular la amortiguación se utilizan sensores y actuadores asistidos con electrónica, de tal manera que, no necesitan aporte externo de energía. La figura 3.12 muestra un esquema de una suspensión semiactiva en el que se distingue el amortiguador regulable (5) y el muelle fijo (4) como principales componentes.




Figura 3.12: Suspensión semiactiva [9]

El principal problema de los amortiguadores con electroválvulas que se utilizan en la suspensión semiactiva es que suponen un alto coste energético y que tienen un alto tiempo de respuesta. Por ello, se empezaron a utilizar otros amortiguadores como los amortiguadores MR, los cuales tienen bajo tiempo de respuesta y menor coste energético. Debido a la importancia de los amortiguadores MR en este proyecto, se describirán con detalle en el capítulo 4 (“Fluidos magneto-reológicos”) una vez se haya explicado qué son los fluidos MR en los cuales se basa el comportamiento de dichos amortiguadores.

CAPÍTULO 4

FLUIDOS MAGNETO- REOLÓGICOS

4.1. INTRODUCCIÓN

La palabra reología fue introducida por primera vez por Eugene Bingham en 1929, catedrático estadounidense y director del departamento de Química del Lafayette College.

La reología es la ciencia que se encarga del estudio de la deformación y del fluir de la materia, más específicamente, de fluidos. Se centra en el comportamiento de materiales que sufren el efecto de esfuerzos externos y que no obedecen las leyes de viscosidad de Newton y de Hooke. Mediante el análisis del campo de deformación aplicado, la reología puede determinar una serie de ecuaciones constitutivas o modelos matemáticos que permiten deducir las funciones y características de dicho material. El estudio de la reología es importante en diversas industrias como pueden ser las de detergentes, plásticos, alimentación o aceites lubricantes, entre otras.

El origen de la reología se remonta a finales del siglo XVII cuando en 1678 Robert Hooke publicó su libro “Verdadera historia de la elasticidad” y, posteriormente, en 1687 Isaac Newton publicó una hipótesis sobre el estado simple de cizalladura o corte que hace referencia al fluir de los materiales. Las leyes lineales de Hooke y Newton se pusieron en duda a mitad del siglo XIX y, por ello, actualmente la reología moderna estudia materiales más complejos con propiedades viscoelásticas [19, 20, 24].

4.2. MATERIALES INTELIGENTES

Los materiales inteligentes, también llamados activos o multifuncionales, son aquellos capaces de reaccionar de modo reversible y controlable a estímulos físicos o químicos externos modificando alguna de sus propiedades. Debido a su capacidad de actuación, estos materiales

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

pueden ser utilizados para el diseño y desarrollo de actuadores y sensores, así como la creación de estructuras y diversos sistemas inteligentes con múltiples aplicaciones. En el caso de estructuras inteligentes son aquellas capaces de autoadaptarse para conseguir las condiciones de operación que se le hayan marcado como óptimas o válidas.

La gran mayoría de los materiales inteligentes han sido descubiertos en los últimos años, aunque también hay algunos conocidos desde hace más tiempo. Pueden ser tanto de carácter orgánico, inorgánico o metálico. Su comportamiento es muy variado y son capaces de reaccionar a muy diversos estímulos de naturaleza física o química.

La evolución de estos materiales es constante, algunos de los primeros que se descubrieron ya están siendo sustituidos por otros de más reciente aparición.

Según su comportamiento o al estímulo al que responden existen diferentes clasificaciones para los materiales inteligentes. Pueden ser materiales electro y magnetoactivos (magneto-reológicos), materiales fotoactivos (fluorescentes, electroluminiscentes), materiales cromóactivos (termocrómicos, piezocrómicos), materiales con memoria de forma (aleaciones metálicas, polímeros), etc. Debido al tema de interés del proyecto, se detallarán solamente los materiales magneto-reológicos [21].

4.3. FLUIDOS MAGNETO-REOLÓGICOS

Los fluidos magneto-reológicos (MR) están compuestos por partículas ferromagnéticas de tamaño nano o micrométrico. Estas partículas están sumergidas en un líquido portador que tiene propiedades viscoelásticas controlables mediante la aplicación de un campo magnético externo. Dependiendo del tamaño de las partículas magnéticas se distingue entre ferro-fluidos, si las partículas tienen un tamaño de 3 a 15 nm y fluidos MR si se encuentran entre las 0,05 y las 8 micras.

La aplicación de un campo magnético constante sobre estos fluidos crea un momento dipolar en las partículas contenidas en él que produce una fuerza atractiva provocando la alineación de éstas en la dirección del campo magnético (ver figura 4.1). La alineación de las partículas paralela al campo magnético produce un incremento de las características viscosas del fluido como puede observarse en la figura 4.1. La energía necesaria para producir estas estructuras columnares va incrementando al ir aumentando el campo magnético [21].




Figura 4.1: Alineación partículas metálicas [21]

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

Estos fluidos tienen tanto propiedades magnéticas como reológicas:

- *Propiedades reológicas:* Las propiedades reológicas de estos fluidos están determinadas principalmente por la concentración y densidad de las partículas, su distribución y forma, propiedades del líquido portador, aditivos adicionales, intensidad del campo magnético aplicado y por la temperatura.
- *Propiedades magnéticas:* En cuanto a las propiedades magnéticas, hay que destacar que los mejores materiales para la utilización de estos fluidos en amortiguadores MR son los materiales super-paramagnéticos. La primera reacción al aplicar el campo magnético es la alineación de las partículas en la dirección de este campo, provocando una estructura fibrosa que modifica las propiedades del fluido. Al quitar el campo magnético, las partículas metálicas no quedan magnetizadas y el fluido MR se comporta como un fluido newtoniano normal. Esta última característica se debe a las propiedades del material super-paramagnético que carece de histéresis magnética.

Ante la ausencia de un campo magnético, los fluidos MR se comportan como fluidos newtonianos. Por lo tanto, ante una velocidad de deformación, surge un esfuerzo viscoso que es proporcional a dicha velocidad a través del fluido.

Cuando los esfuerzos son inferiores al de fluencia, los fluidos MR se comportan como sólidos viscoelásticos. La mayor ventaja de estos fluidos es que para conseguir una determinada velocidad de deformación hace falta un esfuerzo superior al que se necesitaría con otros fluidos, pudiéndose controlar este esfuerzo mediante un campo magnético exterior. Esto significa que el esfuerzo de fluencia aumenta con el campo magnético exterior, no que aumente la viscosidad.

En la figura 4.2 se muestra una gráfica comparativa entre las características de un fluido reológico y un fluido newtoniano. Como se observa, al aumentar la intensidad de campo, el esfuerzo viscoso aumenta en ambos casos (siendo mayor en el fluido reológico) y lo mismo ocurre con el esfuerzo de fluencia [23].




Figura 4.2: Características fluido reológico [22]

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

4.4. APLICACIONES FLUIDOS MAGNETO-REOLÓGICOS

Existen numerosas aplicaciones para los fluidos MR, aunque las más importantes son la obra civil, la robótica, las prótesis médicas y la automoción [22, 23].

- *Obra civil:* Una de las principales aplicaciones de los fluidos MR es la atenuación de vibraciones. En cuanto a las construcciones civiles, estos fluidos se utilizan para atenuar los movimientos producidos por los terremotos y las ráfagas de los vientos en edificios y puentes.

Se han diseñado amortiguadores de gran escala para evitar los efectos sísmicos en edificios. Gracias a su alta fuerza de disipación a baja velocidad, estos amortiguadores permiten un alto control sobre los choques sísmicos iniciales como las réplicas. También se utilizan mucho en los puentes suspendidos por cables al proporcionar un control constante frente a las tensiones producidas por el viento y la lluvia en los cables.

Uno de los países que más ha innovado en este campo es Japón, donde ya se han instalado dispositivos de este tipo en construcciones civiles del Museo de Ciencias Emergentes de Japón. Un ejemplo de estos amortiguadores en puentes se encuentra en el puente del Lago Dong Ting en China (ver figura 4.3).



Figura 4.3: Puente del Lago Dong Ting en China [22]

- *Robótica:* En el campo de la robótica el uso de los fluidos MR es de gran importancia, ya que con ellos se puede lograr que las articulaciones de los robots se muevan de manera muy parecida a las articulaciones humanas. En la figura 4.4 se muestra una mano articulada de un robot.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES



Figura 4.4: Mano de robot [41]

- *Prótesis médicas:* De manera similar a la robótica, estos fluidos pueden ser utilizados en las prótesis médicas de piernas amputadas por encima de la rodilla principalmente. Este descubrimiento ha supuesto un gran avance para las prótesis. En la compañía Biedermann Motech utilizan amortiguadores con fluidos MR para sus prótesis, lo que supone una gran mejora en comparación con las prótesis hidráulicas.

En la figura 4.5 se muestran algunas de las prótesis de rodilla que se encuentran actualmente en el mercado.



Figura 4.5: Prótesis de rodilla [42]

- *Automoción:* En el sector de automoción los fluidos MR se utilizan en el sistema de suspensión, en concreto, en los amortiguadores. Este sistema de suspensión permite un alto grado de seguridad y confort ya que, mediante un sistema de control electrónico, puede variar la rigidez de la suspensión en cuestión de milisegundos. La figura 4.6 muestra un amortiguador MR.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES




Figura 4.6: Amortiguador magneto-reológico [22]

También se suelen utilizar en la suspensión de los asientos de vehículos pesados o de largo trayecto, mejorando de esta forma el confort del conductor fundamentalmente.

4.5. AMORTIGUADORES MAGNETO-REOLÓGICOS

Los amortiguadores MR forman parte de un tipo de suspensión semiactiva (ver sección 3.1.2) cuyo descubrimiento puede considerarse bastante reciente ya que los primeros modelos fueron implementados en los años 90. Algunos de los automóviles que utilizan este sistema de suspensión son el Chevrolet Corvette y el Cadillac Seville.

Son amortiguadores monotubo que, en vez de llevar aceite en su interior, tienen un fluido MR y no tienen válvulas electromecánicas. Como se ha explicado en la sección 4.3, los fluidos MR son aquellos que tienen aproximadamente un 40% de partículas magnéticas en su interior. La principal característica de estos amortiguadores es que pueden variar la rigidez de amortiguación mediante la magnetización de estas partículas. Al magnetizarse producen una variación en la viscosidad del fluido consiguiendo una menor o mayor fuerza de amortiguación. La ventaja de estos sistemas es que permiten su regulación con una gran rapidez, siendo el tiempo de respuesta diez veces menor que los sistemas de amortiguación variable regulados por electroválvulas.

Otra ventaja de esta amortiguación es que está dotada de un sistema de control electrónico muy preciso. Este sistema permite variar la capacidad de regulación según la frecuencia de vibración a la que esté sometida la rueda. Se puede conseguir firmeza durante los movimientos amplios de la carrocería y una suspensión suave en los movimientos rápidos de la rueda. Las frecuencias en las que mejores resultados se obtienen utilizando estos amortiguadores son aquellas entre 1 y 4 Hz.

Uno de los sistemas de amortiguación MR más importantes es el sistema MagneRide de Delphi Automotive (ver figura 4.7) ya que fue la primera aplicación industrial de estos amortiguadores. En este sistema la resistencia del amortiguador se puede modificar hasta 1000 veces por segundo, aunque ésta dependerá siempre de la intensidad del campo magnético externo aplicado [10].

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES



Figura 4.7: Sistema MagneRide en un Audi TT Coupé [40]

El fluido que utiliza el sistema MagneRide es una suspensión no coloidal formada por partículas de hierro en un hidrocarburo sintético. Cuando no hay campo magnético, estas partículas están dispersas al azar por todo el fluido. Según aumenta el campo magnético, las partículas se alinean haciendo que el fluido se vuelva fibroso, casi plástico.

El fluido se comporta de manera diferente al pasar por los orificios del amortiguador según sea la viscosidad. Ante la ausencia de campo magnético, la velocidad entre las partículas próximas al orificio y las que fluyen por el resto del fluido es muy diferente. Esta diferencia de velocidad produce un caudal grande y, por ello, el amortiguador se comporta de una manera suave. Sin embargo, al magnetizar las partículas no hay casi diferencia de velocidad entre unas y otras, el fluido se vuelve lento y la dureza del amortiguador aumenta.

La instalación del sistema MagneRide en un vehículo supone la instalación de un electroimán integrado en el amortiguador que será el que produzca el campo magnético externo.

Delphi ha fabricado amortiguadores monotubo para la suspensión McPherson y con carga de gas a presión. Destaca la sencillez de este amortiguador debido a la ausencia de válvulas, además de ser mucho más resistente a la contaminación del fluido y a la cavitación. Para ajustar la intensidad del campo magnético se utiliza una centralita conectada a cinco sensores. Tres de estos sensores se encuentran acoplados en el sistema de estabilidad (ángulo de guiñada, ángulo de dirección y aceleración transversal) y los otros dos son la posición relativa de las ruedas y la velocidad del vehículo. Además esta centralita, en Delphi, también tiene un sistema de control de la altura constante.

Los amortiguadores MR pueden trabajar con temperaturas comprendidas entre los -40°C y los 70°C . La máxima potencia que necesitan estos amortiguadores es de 20W. El sistema variable de funcionamiento de los amortiguadores MR es parecido al de uno con electroválvulas, duro cuando es necesario y suave cuando es posible. El amortiguador tiende a endurecerse cuando es necesario limitar los rebotes del muelle para mantener el contacto con el suelo, ya sea por motivos de estabilidad o de frenada.

CAPÍTULO 5

MODELOS DE AMORTIGUADORES MAGNETO- REOLÓGICOS

5.1. INTRODUCCIÓN

La modelización de los amortiguadores MR consiste en encontrar una manera de expresar el comportamiento de estos dispositivos a través de ecuaciones o modelos matemáticos. Los amortiguadores MR tienen un comportamiento no lineal ya que presentan histéresis al aplicarles un campo magnético. Este comportamiento no lineal hace que sea muy difícil su modelización.

Existen dos tipos de modelos de amortiguadores MR: los modelos paramétricos y los no paramétricos. Los primeros están basados en características físicas del amortiguador, como pueden ser los resortes. Los modelos no paramétricos están basados en características que no tienen interpretación física, se expresan mediante ecuaciones matemáticas como polinomios. A través de estas ecuaciones se obtienen los valores de las variables deseadas pero no pueden explicarse físicamente.

Los modelos de amortiguadores MR también se dividen en modelos directos y en modelos inversos. La principal diferencia entre unos modelos y otros son las variables de entrada y la variable de salida. En los modelos directos se obtiene la fuerza de amortiguación deseada cuando se conoce la corriente que es necesaria aportar al dispositivo para obtener dicha fuerza. En los modelos inversos, se estima la corriente a la que se debe alimentar el amortiguador para que ejerciera la fuerza deseada. Se han realizado numerosos estudios de los modelos de amortiguadores MR directos, mientras que de los modelos inversos todavía no se han estudiado en profundidad debido a su gran complejidad y dificultad de modelización. Una de las formas de modelizar un modelo inverso es a través de redes neuronales [25, 26, 27].

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

5.2. MODELOS PARAMÉTRICOS

Los modelos paramétricos se basan en determinar características físicas de los muelles o del amortiguador para modelizarlo. Para fijar los parámetros de cada uno de ellos se hacen diferentes ensayos con el dispositivo. Se han realizado numerosos estudios de este tipo de modelo de amortiguador.

En los modelos paramétricos la señal de salida suele ser la fuerza de amortiguación. Esta fuerza depende de la corriente que se aplica al amortiguador al ser atravesado por un campo magnético.

A lo largo de los años se han desarrollado diversos modelos paramétricos que se utilizan en los amortiguadores MR. Los más utilizados en la actualidad se dividen en dos categorías: los que utilizan ecuaciones diferenciales no lineales (el modelo de Bouc- Wen, el de Bouc- Wen modificado, el de Dahl modificado y el de fricción de LuGre modificado) y los que se basan en modelos algebraicos (el modelo de Kwok, el modelo algebraico y el algebraico modificado). A continuación se detallan un poco más las características de estos modelos [25, 26].

5.2.1. MODELOS DIFERENCIALES

Los modelos diferenciales se basan en la utilización de ecuaciones diferenciales no lineales para la modelización de los amortiguadores MR. Existen diferentes modelos de este tipo:

- a) Modelo de Bouc- Wen: Este es uno de los primeros modelos paramétricos utilizados para el modelado dinámico de dispositivos con histerésis ya que es muy versátil y presenta una gran variedad de comportamientos histeréticos. En la figura 5.1 se muestra un esquema simplificado de este modelo en un amortiguador MR.




Figura 5.1: Modelo de Bouc-Wen para amortiguador MR [25]

El modelo de Bouc-Wen fue descrito por Spencer et al mediante la siguiente ecuación:

$$F = C_0 \dot{x} + k_0 (x - x_0) + \alpha z \quad (5.1)$$

Donde la variable z está gobernada por la ecuación 5.2:

$$\dot{z} = -\gamma \dot{x} z |z|^{n-1} - \beta \dot{x} z^n + A \dot{x} \quad (5.2)$$

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

Ajustando los parámetros de esta ecuación (γ , β y A) se puede controlar el comportamiento dinámico del amortiguador MR.

- b) Modelo de Bouc- Wen modificado: Este modelo surgió como mejora del modelo de Bouc-Wen. El primer modelo no tenía en cuenta la respuesta no lineal de fuerza-velocidad en las que las magnitudes de la velocidad tenían valores pequeños. Por ello, se propuso el modelo de Bouc-Wen modificado, el cual predecía el comportamiento dinámico de los amortiguadores MR en esta región. En este caso, la fórmula que describe este modelo es la 5.3:

$$F = \alpha z + C_0 \dot{x} - y + k_0 (x - y) + k_1(x - x_0) \quad (5.3)$$

donde la variable z está definida por la expresión:

$$\dot{z} = -\gamma \dot{x} - y \dot{z} z^{n-1} - \beta(x - y) \dot{z} z^n + A(x - y) \quad (5.4)$$

donde,

$$y = \frac{1}{(C_0 + C_1)} \cdot \{\alpha z + C_0 \dot{x} + k_0 (x - y)\} \quad (5.5)$$

donde,

- k_1 es la dureza del acumulador
- C_0 es la viscosidad del amortiguador a grandes velocidades
- C_1 es un coeficiente que se utiliza para representar el roll-off detectado en los datos experimentales a bajas velocidades
- k_0 es la rigidez a altas velocidades
- x_0 es el desplazamiento inicial asociado de k_1 asociado a la fuerza nominal del amortiguador a causa del acumulador

En la figura 5.2 se muestra un modelo esquemático del modelo de Bouc-Wen modificado para un amortiguador MR.




Figura 5.2: Modelo de Bouc-Wen modificado para amortiguador MR [25]

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

- c) Modelo de Dahl modificado: El modelo de Dahl modificado fue utilizado en vez del modelo de Bouc-Wen porque la histéresis de Dahl simula la fuerza de Coulomb para evitar estimar demasiados parámetros. Este modelo calculaba de manera más correcta la relación fuerza-velocidad a bajas velocidades. La fuerza producida por el amortiguador MR viene dada por la ecuación 5.6:

$$F = k_0 x + C_0 \dot{x} + F_d z - f_0 \quad (5.6)$$

donde,

- k_0 es la dureza del muelle lineal
- C_0 es el coeficiente de amortiguación
- F_d es la fuerza de Coulomb modulada por el campo magnético aplicado
- x es el desplazamiento del amortiguador MR
- f_0 es la fuerza del amortiguador
- z es la variable que viene gobernada por la expresión 5.7

$$z = \sigma x (1 - z \operatorname{sgn} \dot{x}) \quad (5.7)$$

donde,

- σ determina la forma del bucle de histéresis

Para poder calibrar el modelo de Dahl modificado al aplicar un campo magnético, es necesario hallar la relación entre los parámetros del modelo y el campo magnético aplicado. Esta relación se obtiene mediante la ecuación 5.8:

$$C_0 = C_{0s} + C_{0d}u, \quad F_d = F_{ds} + F_{dd}u \quad (5.8)$$

donde,

- C_{0s} es el coeficiente de amortiguación a 0 V
- F_{ds} es la fuerza de Coulomb a 0 V
- u es la variable intrínseca para determinar la dependencia de los parámetros al voltaje aplicado (V)

La relación entre u y V se expresa mediante la ecuación 5.9:

$$u = -\eta(u - V) \quad (5.9)$$

donde,

- η refleja el tiempo de respuesta, cuanto mayor sea η , menor es el tiempo de respuesta
- V es el voltaje aplicado

El modelo de Dahl modificado implica ocho parámetros ($C_{0s}, C_{0d}, F_{ds}, F_{dd}, k_0, \sigma, f_0$ y η) que deben ser determinados a partir de datos experimentales. En la figura 5.3 se muestra el modelo de Dahl modificado.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES




Figura 5.3: Modelo de Dahl modificado para un amortiguador MR [25]

- d) Modelo de fricción de LuGre modificado: Este modelo es una continuación al modelo de Dahl para explicar el comportamiento dinámico de los amortiguadores MR y ha sido utilizado para múltiples aplicaciones relacionadas con la fricción. Debido a su sencillez matemática y a su alta precisión, este modelo es un gran candidato en problemas de modelado y diseño. El modelo se expresa matemáticamente mediante las ecuaciones 5.10:

$$F = f_0 + \beta z + \gamma x + \delta \dot{x} + \varepsilon \dot{z} \quad (5.10)$$

$$\dot{z} = x - \alpha |x| z$$

donde,

- α [mm^{-1}], β [Nmm^{-1}], γ [$\text{Ns} \text{mm}^{-1}$] y ε [$\text{Ns} \text{mm}^{-1}$] son parámetros generales de la dureza y amortiguación que varían con la corriente aplicada
- F [N] es la fuerza total de amortiguación aplicada por el amortiguador MR
- x [mm] es el desplazamiento del amortiguador
- z [mm] está relacionado con la deformación del fluido MR que se encuentra en el interior del cilindro del amortiguador

5.2.2. MODELOS ALGEBRAICOS

Los modelos algebraicos son un tipo de modelos paramétricos entre los que destacan los siguientes:

- a) Modelo de Kwok: Este modelo utiliza la función tangente hiperbólica para representar la histéresis y funciones lineales para representar la viscosidad y la dureza. La representación matemática del modelo viene dada por las expresiones:

$$F = cx + kx + \alpha z + f_0 \quad (5.11)$$

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

$$z = \tanh \beta x + \delta \operatorname{sgn}(x)$$

donde,

- c es el coeficiente de viscosidad
- k es el coeficiente de dureza
- α es el factor de escala de la histéresis
- z es la variable de histéresis dada por la función tangente hiperbólica
- f_0 es el offset del amortiguador

En la figura 5.4 se muestra un modelo esquematizado del modelo de Kwok.




Figura 5.4: Modelo de Kwok para amortiguador MR [25]

- b) Modelo algebraico: Se trata de otro modelo sencillo para modelar la histéresis de un amortiguador MR. El modelo se representa matemáticamente mediante la ecuación 5.12:

$$F = f_0 + c_b x + \frac{2}{\pi} f_y \arctan\{k x - x_0 \operatorname{sgn} x\} \quad (6.12)$$

donde,

- F es la fuerza de amortiguación
 - f_0 es la pre-carga del acumulador de gas
 - c_b es el coeficiente de viscosidad
 - f_y es la fuerza del límite elástico
 - k es el coeficiente de forma
 - x_0 es la velocidad histerética
 - x es la velocidad de entrada
 - \dot{x} es la aceleración del pistón de amortiguador
- c) Modelo algebraico modificado: El primer modelo algebraico mostraba una buena correlación entre los valores estimados y los valores medidos excepto a bajas corrientes (0 y 0,2 A). Esto se debe principalmente a la fuerza de inercia del fluido ya que empieza a notarse a bajas corrientes. Siguiendo este razonamiento, se modifica la expresión 6.12 del modelo algebraico y se le añade un término de fuerza de inercia como puede verse

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

en la expresión 6.13. Esta modificación es necesaria para mejorar la coincidencia entre los valores estimados y los valores medidos. Por lo tanto, el modelo algebraico modificado se expresa mediante la ecuación 6.13:

$$F = f_0 + c_b x + \frac{2}{\pi} f_y \arctan k x - x_0 \operatorname{sgn} x + mx \quad (6.13)$$

donde,

- m representa una masa virtual que debe ser calculada a partir de datos experimentales

5.3. MODELOS NO PARAMÉTRICOS

Los modelos no paramétricos son aquellos que utilizan expresiones matemáticas para explicar el funcionamiento del amortiguador MR, por ejemplo, polinomios. Este tipo de modelo es el utilizado en este Trabajo de Fin de Grado, en concreto, un modelo no paramétrico basado en redes neuronales. En este tipo de modelos se estima la corriente con la que es alimentada el amortiguador para conseguir una fuerza de amortiguación deseada.

En los modelos paramétricos se explicó un modelo creado por Spencer (el modelo de Bouc-Wen) en el cual, a partir de una fuerza de amortiguación, se conseguía la corriente necesaria. El gran inconveniente de estos modelos es su complejidad matemática. Es por ello, que se tiende a utilizar modelos no paramétricos que proporcionen directamente la intensidad de corriente deseada.

Los modelos no paramétricos pueden simularse de manera correcta mediante la utilización de redes neuronales, ya que éstas permiten la resolución de sistemas de ecuaciones no lineales bastante complejos. Al utilizar estas redes es de vital importancia la estructura de la red, es decir, el número de capas y de neuronas en cada capa así como los pesos sinápticos entre las conexiones de las neuronas. El problema de las redes neuronales es que no existe un modelo único de red que resuelva un problema, depende de la experiencia del diseñador encontrar o no la red óptima. Por ello, el uso de estas redes puede suponer muchos análisis y estudios hasta encontrar la red que mejor se adapte al problema.

Varios estudios han demostrado que una buena manera de obtener el mejor rendimiento de la red neuronal en el caso de un modelo no paramétrico es añadir capas ocultas. La dificultad reside en saber cuántas capas ocultas hay que añadir, siempre debe haber capas ocultas para conseguir buenos resultados. Sin embargo, en modelos directos a veces una capa oculta puede ser suficiente, mientras que en modelos inversos se ha demostrado que añadiendo capas ocultas suelen conseguirse mejores resultados. Hay que tener en cuenta que si se añaden demasiadas, el rendimiento disminuye. Otra manera de aumentar el rendimiento, es utilizar un método que elimina los pesos innecesarios de la red. El funcionamiento de una red neuronal se explica con detalle en el capítulo 6 [27].

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

5.3.1. MODELO INVERSO BASADO EN REDES NEURONALES

Una de las maneras de modelizar un modelo inverso de amortiguador MR es a través de redes neuronales como se explicará en el capítulo 6. Los modelos directos explicados en la sección 5.2 se basaban principalmente en dos variables; por un lado, el desplazamiento (x) del pistón y, por otro, el voltaje aplicado (V). Existen modelos basados en redes neuronales que utilizan como variables principales el desplazamiento, el voltaje y la fuerza para simular el comportamiento de los amortiguadores MR. A partir de estos estudios, se considera la posibilidad de simular el comportamiento de un modelo inverso que, como ya se ha dicho, tiene como salida el voltaje o la intensidad requerida en función del desplazamiento del pistón, la fuerza generada y valores anteriores del voltaje.

El modelado inverso de un amortiguador MR se considera un problema de identificación de patrones. Este proceso puede dividirse en los cuatro pasos siguientes:

1. Recopilar una serie de datos que describan el comportamiento del amortiguador dentro de un cierto rango: para obtener unos óptimos resultados, lo mejor es analizar un gran volumen de datos. Normalmente se miden experimentalmente muchos datos para luego hacer una selección. Esta selección de datos será la utilizada para el modelado en el software de redes neuronales, dependiendo de la función de activación utilizada será necesario normalizar los datos entre un intervalo de valores que suele ser $(-1, 1)$ o $(0, 1)$.
2. Determinar la tipología de la red, es decir; número de capas de entrada, salida y capas ocultas, número de neuronas en cada capa, función de activación, etc. Como se explica en la sección 6.2.2 este es uno de los pasos más determinantes en el modelado del amortiguador. Los resultados dependen en gran medida de la función de activación utilizada así como de la estructura de la red.
3. Entrenamiento y aprendizaje de la red creada: dependiendo del tipo de aprendizaje que se utilice (ver sección 6.3.1) este paso tendrá más o menos importancia. Hay aprendizajes en los que existe un supervisor que puede variar ciertos parámetros como es el factor de entrenamiento pero en otros se deja que la red aprenda de manera automática simplemente enseñándole qué valores son válidos y cuáles no.
4. Validación de la red y comprobación de resultados: este es el último paso en el modelado del amortiguador y en el que se comprueba si la red ha aprendido de manera correcta.

Los modelos basados en redes neuronales suelen utilizar el Perceptron multicapa (ver sección 6.2.1). Cada problema debe resolverse con la tipología de red adecuada. El inconveniente es que no existe una única solución para cada problema.

CAPÍTULO 6

REDES NEURONALES ARTIFICIALES

6.1. INTRODUCCIÓN

Las Redes Neuronales Artificiales (RNA) son sistemas de información que se basan en el modo en el que el cerebro humano procesa la información para llegar a resolver problemas de alta dificultad. La mayor novedad de estos sistemas es que utilizan una gran cantidad de elementos interconectados (neuronas) que trabajan al unísono para resolver un problema específico. Estos sistemas funcionan de manera similar al cerebro humano, mediante la experiencia, reconocen patrones a través de un proceso de aprendizaje. Este proceso, tanto en las redes biológicas como en las artificiales, supone la modificación de las conexiones o sinapsis entre las neuronas para llegar a la resolución del problema.

El descubrimiento de las RNA es considerado bastante reciente, sin embargo, este campo de investigación fue establecido incluso antes de la aparición de los ordenadores. Hubo un primer momento de entusiasmo que fue seguido por una época de frustración durante la cual algunos investigadores consiguieron seguir avanzando. La primera RNA fue creada en 1943 por Warren McCulloch y Walter Pits, pero la tecnología disponible en aquella época les impidió realizar grandes avances. Actualmente ha resurgido el interés de las RNA por algunas de sus aplicaciones.

A partir de una serie de datos, una RNA es capaz de extraer un patrón que puede ser utilizado para la resolución de diversos problemas y para el análisis de información. Ésta es una de las muchas ventajas que tienen las RNA, entre las que destacan [31]:

- a) Aprendizaje adaptativo: Es la habilidad de aprender cómo realizar tareas basadas en los datos de aprendizaje o en una experiencia inicial.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

- b) Organización propia: Durante el tiempo de aprendizaje, la RNA es capaz de crear su propio método de organización.
- c) Operación en tiempo real: Existen dispositivos para llevar a cabo los análisis de las RNA en paralelo.

Los ordenadores actuales tienen limitada su capacidad de resolver problemas ya que para ello utilizan algoritmos, es decir, una serie de instrucciones. Por ello, un ordenador es muy útil y rápido en la resolución de problemas que, de alguna manera, ya se sabe cómo resolver. Pero podrían ser mucho más útiles si fuesen capaces de resolver problemas a los que todavía no se ha encontrado la solución. Las RNA trabajan mediante patrones (al igual que el cerebro humano), estos patrones deben ser escogidos con cuidado para ahorrar tiempo o para evitar que la red funcione de manera incorrecta. Pero la gran desventaja de las RNA es que, como encuentra la solución por sí misma, no se puede predecir el resultado.

Por lo tanto, las RNA no son competidoras de los ordenadores, sino que los complementan. Hay tareas que son más aptas para los ordenadores y otras que lo son para las RNA. De hecho, la mayoría de las tareas suelen necesitar de ambos sistemas, ya que el ordenador es el encargado de implementar la red neuronal [29, 30].

6.2. RED NEURONAL ARTIFICIAL

Las Redes Neuronales Artificiales (RNA o “ANN”- *Artificial Neural Network*- en inglés) son modelos matemáticos que se basan en el comportamiento de las neuronas del ser humano y en la estructura del cerebro para poder resolver problemas complejos. Están basadas en el aprendizaje a través de la experiencia. Una sola red puede realizar varias tareas ya que son muy flexibles.

Este tipo de redes pueden ser consideradas también como sistemas inteligentes capaces de resolver problemas muy complejos que las computadoras actuales no pueden. Aunque los ordenadores son muy rápidos en el procesamiento de información, tienen dificultades en la resolución de ejercicios de clasificación o reconocimiento de patrones, pues les llevaría mucho tiempo y esfuerzo llegar a resolverlos. Sin embargo, este tipo de problemas son considerados bastante sencillos para las redes neuronales ya que actúan de manera similar a como lo haría el cerebro humano.

Es necesario entender el funcionamiento de la unidad básica del cerebro humano, la neurona, para llegar a comprender cómo trabaja una RNA. El cerebro es uno de los sistemas más complejos que existen y cuyo funcionamiento se sigue estudiando en la actualidad, está formado por unos diez billones de neuronas en las que hay unos 60 trillones de conexiones neuronales (sinapsis). La mayoría de las neuronas se componen principalmente de tres elementos (ver figura 6.1): el cuerpo de la neurona o soma que es la parte principal, las dendritas que son ramas que reciben las señales de entrada de otras neuronas y el axón que es un filamento que lleva la señal de salida de la neurona hacia otras neuronas.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES




Figura 6.1: Neurona biológica y sus partes [46]

La neurona capta las señales procedentes de otras neuronas a través de las dendritas. Cuando una neurona capta una señal suficientemente fuerte, la neurona se activa y manda a través del axón la señal de salida mediante impulsos eléctricos para que lleguen al resto de neuronas. Al final de cada axón se encuentra la interconexión entre neuronas llamada sinapsis cuya función es transmitir a otras neuronas las señales de salida para activarlas.

El proceso desarrollado en una RNA se basa en la transmisión de información entre neuronas del cerebro humano aunque debe ser adaptado y simplificado. La función de red que activa a la neurona se llama “función de activación”, la cual es muy importante en las RNA como se verá más adelante [28, 29, 30].

6.2.1. PERCEPTON MULTICAPA

El Perceptron multicapa es el modelo de RNA utilizado en este Trabajo de Fin de Grado. Se trata de una RNA que simula el cerebro humano con una estructura dividida en capas, en las cuales hay un número determinado de neuronas (ver figura 6.2). Existe una capa de entrada, una capa de salida y tantas capas intermedias o capas ocultas como se precisen. Por lo tanto, los elementos básicos de una RNA que sigue un modelo de Perceptron multicapa son los siguientes [28]:

- a) Capa de entrada: Es la primera capa que aparece en la RNA, está formada por las neuronas que representan los datos de entrada de la red y que serán las entradas de otras neuronas. Las salidas de estas neuronas llegan a todas las neuronas de la siguiente capa (ver figura 6.2).
- b) Capa oculta: Es la capa intermedia, en ella se encuentran neuronas a las cuales les llegan las salidas procedentes de la capa de entrada y que envían señales hacia la capa de salida. Puede haber tantas capas ocultas como se necesiten o no haber ninguna, ya que, dependiendo de la dificultad del problema a resolver pueden necesitarse más de una capa oculta.
- c) Capa de salida: Es la capa final de la RNA, en ella las neuronas reciben señales desde la capa oculta y producen señales hacia el final de la red. La salida de esta capa es la salida y solución a toda la red.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

La complejidad de una RNA, como puede observarse en la figura 6.2, depende del número de capas ocultas que tenga así como del número de neuronas en cada capa. El número de neuronas en la capa de entrada es el número de datos de entrada que tiene la red y lo mismo ocurre con la salida. Sin embargo, en las capas ocultas se puede variar el número de neuronas hasta encontrar el número óptimo para cada red (el que permita conseguir mejores resultados).




Figura 6.2: Estructura de una RNA [29]

El tipo de redes que se utilizan en este proyecto son redes *feed-forward*, es decir, todos los elementos de una capa anterior están unidos a todas las neuronas de la capa siguiente. Además, lo hacen de manera que se va avanzando en las capas, nunca la señal vuelve hacia atrás, van desde la entrada a la salida. Como las neuronas de una capa reciben las entradas de muchas neuronas, es necesario ponderar dichas señales mediante unos pesos. Las RNA combinan los datos de entrada (*inputs*) multiplicados por sus correspondientes pesos (*weights*) para dar lugar a una o varias señales de salida (*outputs*) [30].

6.2.2. FUNCIÓN DE ENTRADA

La neurona trata muchos valores de entrada como si fuesen uno solo, para poder unificar este valor se utiliza la función de entrada (*input function*). El valor de entrada unificado se llama “entrada global”. Cada valor de entrada se multiplica por su peso correspondiente que ha sido anteriormente establecido en la neurona. Estos pesos pueden variar la influencia de un valor de entrada, ya que, dependiendo de su peso, una entrada influirá más o menos en la red.

En la figura 6.3 se muestra el proceso interno de una RNA. Las entradas (X_1 , X_2 y X_3) son ponderadas mediante unos pesos (W_1 , W_2 y W_3) e introducidas a la red a través de la función de entrada. El resultado de esta función es el sumatorio de todas las entradas multiplicadas por los pesos dando lugar a la “entrada global”. Después actúa la función de activación y se obtiene la salida de la red [30].

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

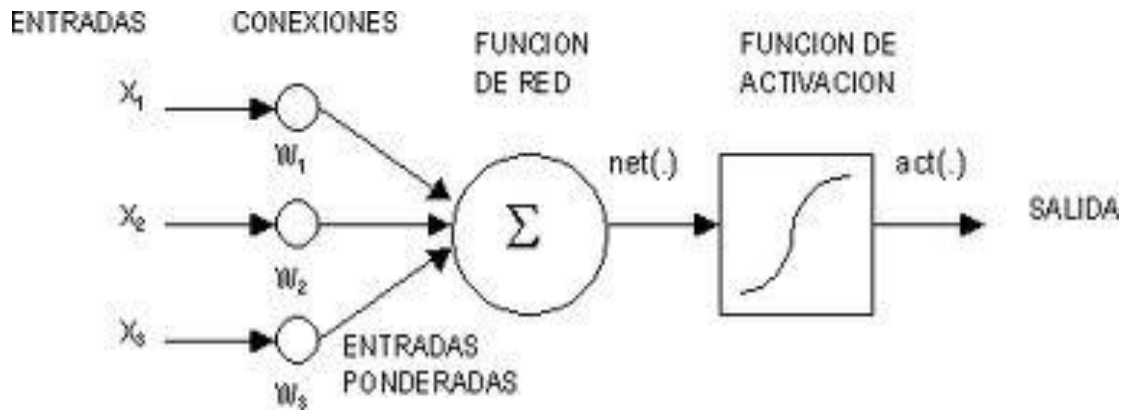


Figura 6.3: Funcionamiento interno de una RNA [30]

Las funciones de entrada pueden variar según la RNA utilizada, las más comunes son las siguientes [31]:

- *Sumatorio de las entradas ponderadas*: Suma de todas las entradas multiplicadas por los pesos correspondientes.

$$\sum_j n_{ij} \cdot w_{ij} , \quad \text{con } j = 1, 2, \dots, n$$

- *Producto de las entradas ponderadas*: Producto de los valores de entrada de la neurona multiplicado por los pesos correspondientes.

$$\prod_j n_{ij} \cdot w_{ij} , \quad \text{con } j = 1, 2, \dots, n$$

- *Máximo de las entradas ponderadas*: Esta función solamente toma como valor, la entrada más fuerte multiplicada previamente por el peso correspondiente.

$$\max_j n_{ij} \cdot w_{ij} , \quad \text{con } j = 1, 2, \dots, n$$

6.2.3. FUNCIÓN DE ACTIVACIÓN

Las neuronas biológicas tienen un “estado de activación” ya que pueden estar activas (excitadas) o inactivas (no excitadas). Con las neuronas artificiales ocurre lo mismo, aunque éstas pueden tener más de dos estados de activación. La función de activación (*activation function*) calcula el nivel de activación de una neurona transformando la entrada global en un valor normalmente entre (0, 1) o entre (-1,1). Esto se debe a que la neurona puede estar completamente activa (1) o inactiva (0 ó -1). Las funciones de activación más utilizadas son las siguientes [31]:

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

- *Función lineal o identidad:* La función de activación lineal es una de las más comunes en RNA. Es una función derivable cuya derivada es una constante de valor 1, por ello, es una función apta para la capa de salida. La gráfica de la función lineal puede observarse en la figura 6.4 y se representa mediante la siguiente fórmula matemática:

$$f(x) = x$$




Figura 6.4: Gráfica y fórmula de la función de activación lineal [31]

- *Función escalón:* Esta función fue la primera función de activación utilizada por el Perceptron. El valor de salida es un número concreto, normalmente toma valor de 1 si la salida total alcanza un cierto valor umbral (neurona activa) o valor de 0 si no alcanza el umbral (neurona inactiva). La gráfica y fórmula matemática de esta función se representan en la figura 6.5.

$$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$$




Figura 6.5: Gráfica y fórmula de la función de activación escalón [31]

La función de activación escalón es muy útil para hacer clasificaciones en dos grupos. Sin embargo, presenta un gran inconveniente, no es derivable en cero. Esto hace que sea muy difícil su aprendizaje y que pueda dar valores erróneos.

- *Función tangente hiperbólica:* Se trata de una función no lineal. Esta función es muy adecuada para utilizarla como función de activación, ya que es derivable en todo su dominio (lo que es preferible en RNA para que aprenda bien la red). Está comprendida en

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

el rango de valores entre (-1,1). En la figura 6.6 se muestra la gráfica de esta función así como su expresión matemática.

$$f(x) = \tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$




Figura 6.6: Gráfica y fórmula de la función de activación tangente hiperbólica [31]

- *Función sigmoideal o función logística:* La función logística es un caso concreto de la función sigmoideal, aunque se suele referir a una u otra indistintamente. Se tratan de funciones muy parecidas a la función tangente hiperbólica, son diferenciables y continuas en todo su dominio. La diferencia con esta función es que la función sigmoideal o función logística está comprendida en el intervalo (0,1). En la figura 6.7 se muestra su ecuación y gráfica. No hay mucha diferencia en utilizar la función tangente hiperbólica o la logística como función de activación de un RNA.

$$f(x) = \frac{1}{1 + e^{-x}}$$




Figura 6.7: Gráfica y fórmula de la función de activación logística o sigmoideal [31]

6.2.4. FUNCIÓN DE SALIDA

La función de salida es el último componente que la neurona necesita (ver figura 6.3). Esta función proporciona la salida de la neurona para que, a través de la sinapsis, se transfiera a otra neurona como señal de entrada o sea la salida de la red. La función más utilizada es la función identidad (ver sección 6.2.3) por ser la más sencilla, es decir, la salida coincide con la entrada de la neurona [31].

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

6.3. APRENDIZAJE DE UNA RED NEURONAL ARTIFICIAL

Una red neuronal tiene como objetivo procesar los datos de entrada para conseguir una salida adecuada. Su método de operación está basado en la experiencia, a partir de un conjunto de datos, la red extrae un comportamiento general o un patrón que toma como ejemplo a la hora de encontrar la salida de un dato determinado. La RNA debe aprender a obtener la salida adecuada para cada conjunto de datos de entrada, a este proceso se le llama “proceso de entrenamiento”. Por este motivo, el conjunto de datos en que se basa este proceso se conoce como “datos de entrenamiento”.

Es importante tener en cuenta que durante el entrenamiento la tipología o estructura de la red y las funciones de la neurona (función de entrada, de activación y de salida) permanecen constantes. Por lo tanto, lo único que varía durante el proceso de entrenamiento de la RNA son los pesos sinápticos, los pesos que ponderan los datos de entrada. Es por ello que el proceso de entrenamiento se basa en la “adaptación de los pesos”, para poder encontrar los pesos que mejores resultados proporcionan a la red.

En definitiva, el aprendizaje de una RNA es el proceso durante el cual una neurona modifica sus pesos sinápticos como respuesta a unos datos de entrada. Estos cambios en los pesos suponen la creación, destrucción y modificación de las conexiones entre neuronas. Del mismo modo, en una red biológica, se crean y destruyen continuamente las sinapsis entre las neuronas. En cuanto a las redes artificiales, la creación de una conexión se produce cuando el peso de la neurona adquiere un valor distinto de cero; un peso igual a cero supone la destrucción de dicha conexión. Hasta que los valores de los pesos no adquieren valores estables la red está aprendiendo, cuando éstos se estabilizan se puede considerar que el proceso de entrenamiento ha finalizado.

Al principio del entrenamiento debe escogerse el valor de los pesos. El método más común y el que se ha demostrado que es el más beneficioso es dar un valor aleatorio que suele estar comprendido en un intervalo del estilo $[-n, n]$, donde n es un número positivo. A lo largo del entrenamiento el valor de los pesos varía pero siempre permanece en dicho intervalo.

También es importante tener en cuenta que los datos de entrada deben estar codificados, es decir, según la función que de activación que se vaya a utilizar deberán estar comprendidos en un intervalo o en otro. Teniendo en cuenta las funciones de activación estudiadas, los valores de entrada suelen estar normalizados entre $(-1,1)$ o $(0,1)$.

El proceso de aprendizaje se detiene cuando se cumple una “condición de detención”. Esta condición suele ser cuando el error cuadrático alcanza un valor mínimo o está por debajo de un valor umbral. Esto se debe a que la mayoría de los programas de redes neuronales proporcionan una herramienta que permite visualizar diferentes gráficas de error. Estas gráficas dan una idea del avance del proceso pero no son utilizadas para el aprendizaje. Cuando el proceso de aprendizaje finaliza significa que los pesos ya no cambian su valor.

Es necesario conocer la manera en que se modifican los pesos para poder entender el proceso de aprendizaje de la RNA. Es decir, hay que saber qué criterios se sigue para modificar cada una de las conexiones y conseguir que la red aprenda una información. Existen dos métodos de aprendizaje: el aprendizaje supervisado y el aprendizaje no supervisado. A continuación se explica con detalle cada uno de estos métodos [31].

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

6.3.1. APRENDIZAJE SUPERVISADO

El aprendizaje supervisado se basa en la existencia de un maestro o supervisor externo a la RNA que determina cuál debe ser la respuesta o salida a una determinada entrada durante el proceso de aprendizaje. La misión del supervisor es vigilar la salida de la red y, cuando ésta difiera del valor que debería obtener la red, modificar los pesos de las conexiones para conseguir que la red aprenda el valor deseado. Existen tres tipos diferentes de aprendizajes supervisados: aprendizaje por corrección de error, por refuerzo y estocástico.

- a) Aprendizaje por corrección de error: Este tipo de aprendizaje se basa en ajustar los pesos de las conexiones en función del error cometido entre la salida conseguida y la salida deseada.

Este aprendizaje se utilizó en la red llamada “Perceptron” creada en 1958 por Rosenblatt y se denominó “la regla del aprendizaje del Perceptron”. Para cada neurona de salida se calcula la desviación δ con respecto al valor deseado. Este error se utiliza para cambiar los pesos sobre la conexión de la neurona anterior mediante la siguiente expresión:

$$\Delta w_{ij} = \sigma \cdot out_j \cdot a_{qi} - out_i = \sigma \cdot out_j \cdot \delta_i$$

donde,

- a_{qi} es la salida deseada de la neurona de salida N_i
- δ_i es el error cometido con respecto al valor deseado
- σ es el aprendizaje.

Se utiliza el valor de salida de la neurona (out_j) porque este valor afecta a la entrada global y, por tanto, a la salida de la neurona.

Otro algoritmo de este tipo es la “regla de aprendizaje Delta” o “regla del mínimo error cuadrado” (LMS: Least Mean Squared Error) que también se basa en el error cometido en la salida, pero teniendo en cuenta todas las neuronas que preceden a la neurona de salida. De esta manera se calcula el error global producido en toda la red, de vital importancia ya que cuanta más información sobre el error se conozca, más rápido se puede aprender. El error δ obtenido se reparte posteriormente entre todas las neuronas predecesoras.

Existe una última regla que se basa en la generalización de la “regla del aprendizaje Delta” y se conoce como “regla de propagación hacia atrás” o “regla *Backpropagation*”. Esta regla es muy importante ya que fue la primera que permitió modificar el valor de los pesos durante el aprendizaje. Como es el método utilizado en este Trabajo, en la sección 6.4 se explica con detalle su funcionamiento.

- b) Aprendizaje por refuerzo: El aprendizaje por refuerzo es un aprendizaje supervisado más lento que el anterior. La principal diferencia es que no se tiene un ejemplo completo del valor de la salida deseada, es decir, no se sabe exactamente el valor de salida que tiene que dar la red ante una entrada concreta.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

En este caso, el supervisor se limita a dar una señal de refuerzo a la red neuronal para indicar si la salida es válida o no (éxito= +1 y fracaso= -1) y a partir de esto, los pesos se ajustan siguiendo un mecanismo de probabilidades. Se puede considerar que en este caso el supervisor actúa como un crítico del comportamiento de la red (opina sobre éste) mientras que en el caso de corrección del error, actuaba como un maestro ya que mostraba la respuesta correcta a la red.

- c) Aprendizaje estocástico: Se basa en realizar modificaciones en los pesos de manera aleatoria, estudiar el efecto producido según el objetivo deseado y estudios de probabilidad. Normalmente, en este tipo de aprendizaje se hace una analogía de la red en términos termodinámicos considerándola como un sólido físico que tiene cierto estado energético. De esta manera, la energía de la red representa su grado de estabilidad, cuánta menos energía más estable es la red, es decir, los pesos de las conexiones son los que más se ajustan a los valores objetivo deseados.

Por lo tanto, su funcionamiento consiste en realizar un cambio aleatorio a los pesos y estudiar el grado de energía de la red. Si la energía es menor después de realizar el cambio, éste se acepta; si la energía es mayor, el cambio no se acepta.

6.3.2. APRENDIZAJE NO SUPERVISADO

El aprendizaje no supervisado no depende de ningún agente externo para ajustar los valores de los pesos de las conexiones, no hay un supervisor que indique si la salida obtenida es correcta o no. La función de las redes es encontrar las correlaciones, categorías o características que haya entre los datos de entrada. Dependiendo del algoritmo de aprendizaje utilizado y de la estructura de la red se pueden interpretar de una manera u otra los resultados obtenidos.

Existen casos en los que la red muestra el grado de familiaridad de los resultados con los datos previamente mostrados. Hay otras ocasiones en las que la red lo que muestra es la categoría a la que pertenece la información de entrada, siendo necesario después que la red determine las categorías apropiadas. Existen fundamentalmente dos tipos de aprendizajes no supervisados: el aprendizaje hebbiano y el aprendizaje competitivo y comparativo.

- a) Aprendizaje hebbiano: Esta regla de aprendizaje se basa en medir la familiaridad o extraer características de los datos de entrada. Este aprendizaje sigue el fundamento de que si dos neuronas se encuentran en el mismo estado (ambas activas o inactivas), el peso de conexión entre ambas aumenta. En este caso, la salida de la neurona solamente puede tomar los valores $\{-1, 1\}$ ya que esta regla surgió a partir de la neurona biológica que solo puede presentar dos estados: activa o inactiva.
- b) Aprendizaje competitivo y comparativo: Está basado en la clasificación de los datos de entrada en categorías. Su característica principal consiste en que si un patrón pertenece a una categoría que ya ha sido creada, al incluir dicho patrón, se matiza la representación de esta categoría. En el caso contrario de que el patrón de entrada no pertenezca a ninguna categoría conocida, entonces los pesos deben ser ajustados para crear la nueva categoría.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

6.3.3. REGLA DE APRENDIZAJE *BACKPROPAGATION*

La regla de aprendizaje *backpropagation* para redes multicapa es una de las más importantes en el aprendizaje de las RNA y la utilizada en este Trabajo. Es una generalización de la regla LMS (*Least Mean Square*- ver sección 6.3.1), ambas varían los pesos de las conexiones en base al análisis del error cuadrático medio. La red *backpropagation* es un tipo de entrenamiento supervisado, por lo que necesita un conjunto de datos de entrada y salida de la siguiente forma [32]:

$$p_1, t_1, p_2, t_2, \dots, p_q, t_q$$

donde,

- p_q son las entradas a la red
- t_q es la correspondiente salida

La red tiene como objetivo minimizar el error cuadrático medio. El primer paso para poder comenzar el entrenamiento de la red es definir su tipología. Es decir; definir el número de neuronas en la capa de entrada (número de componentes en el vector de entrada), el número de capa de ocultas y la cantidad de neuronas en cada una de ellas, el número de neuronas en la capa de salida (número de componentes en el vector de salida) y funciones de activación, entrada y salida de cada capa (ver secciones 6.2.2, 6.2.3 y 6.2.4 respectivamente). Un detalle importante a tener en cuenta es que no existe ningún mecanismo específico para determinar el número óptimo de capas ocultas o el número de neuronas en éstas, depende de la experiencia del diseñador y de los límites computacionales.

Los patrones de entrenamiento se propagan hacia la salida y se compara el valor obtenido con el valor objetivo correspondiente calculando así el error. Este error marca el camino para variar los pesos y poder al final del entrenamiento conseguir los valores adecuados, para ello hay que ir disminuyendo el error hasta conseguir un valor mínimo.

Se va a explicar el procedimiento matemático de la regla de aprendizaje *backpropagation* a partir de la red mostrada en la figura 6.8. Se trata de una red sencilla con una capa de entrada, una capa oculta y una capa de salida, para luego generalizar el procedimiento a un número mayor de capas.




Figura 6.8: Red neuronal sencilla [32]

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

En la figura 6.8 se representa una red sencilla con una capa de entrada con “q” componentes, una única capa oculta que contiene “m” neuronas y una capa de salida con “l” componentes.

El vector de la capa de entrada se representa con “q” componentes y se escribe de la siguiente manera:

$$P = \begin{bmatrix} p_1 \\ p_2 \\ \vdots \\ p_i \\ \vdots \\ p_q \end{bmatrix} \quad (6.1)$$

donde,

- P es el vector de entrada
- p_q es el número total de componentes o neuronas que contiene el vector entrada

Al introducir en la red neuronal un patrón de entrenamiento, éste se va propagando hacia todas las neuronas de tal manera que, en cada neurona de la siguiente capa, se crea una entrada neta (n). Este valor de entrada es el que se produce justo antes de aplicar la función de activación, como se muestra en la ecuación 6.2 (valor de una entrada de la neurona “j”):

$$n_j^o = \sum_{i=1}^q W_{ji}^o \cdot p_i + b_j^o \quad (6.2)$$

donde,

- n_j^o es la entrada neta de la neurona “j”
- W_{ji}^o es el peso que une la componente “i” de la entrada con la neurona “j” de la capa oculta.
- p_i es la componente “i” del vector de entrada P
- b_j^o es la ganancia de la neurona “j” de la capa oculta

El superíndice (°) representa la capa a la que pertenece cada parámetro, siendo en este caso la capa oculta.

En cuanto a la salida de las neuronas de la capa oculta, denominada como a_j^o , se calcula mediante la expresión 6.3:

$$a_j^o = f^o \cdot \left(\sum_{i=1}^q W_{ji}^o \cdot p_i + b_j^o \right) \quad (6.3)$$

donde,

- a_j^o es la salida de la neurona “j” de la capa oculta
- f^o es la función de transferencia de las neuronas de la capa oculta

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

Una vez que se ha alcanzado las salidas a_j^o de la capa oculta, éstas pasan a la entrada de la capa de salida mediante los pesos de conexión entre neuronas. Este comportamiento se describe en la ecuación 6.4.

$$n_k^s = \sum_{i=1}^m W_{kj}^s \cdot a_j^o + b_k^s \quad (6.4)$$

donde,

- n_k^s es la entrada neta a la capa de salida de la neurona “k”
- W_{kj}^s es el peso que une la neurona “j” de la capa oculta con la neurona “k” de la capa de salida, en la cual hay “s” componentes
- b_k^s es la ganancia de la neurona “k” de la capa de salida

La salida final de la capa de salida y, por tanto, la señal final de la red o señal de salida viene determinada por la función 6.5.

$$a_k^s = f^s \cdot n_k^s \quad (6.5)$$

donde,

- a_k^s es salida de la neurona “k” de la capa de salida
- f^s es la función de transferencia de las neuronas de la capa de salida

Si se sustituye la ecuación 6.4 en la ecuación 6.5 se puede obtener la salida de la capa de salida en función de la entrada neta y los pesos de conexión en la capa oculta (ver ecuación 6.6).

$$a_k^s = f^s \cdot \left(\sum_{i=1}^m W_{kj}^s \cdot a_j^o + b_k^o \right) \quad (6.6)$$

En el proceso de entrenamiento, el valor de salida obtenido en la red a_k^s , se compara con el valor objetivo o valor deseado t_k para poder encontrar el error δ_k cometido. Este error se calcula de la siguiente manera (ver ecuación 6.7):

$$\delta_k = t_k - a_k^s \quad (6.7)$$

donde,

- δ_k es el error cometido en cada neurona durante el proceso de entrenamiento
- t_k es el valor deseado de salida

Las redes neuronales calculan el error cuadrático medio y lo representan gráficamente para poder visualizar cómo transcurre el proceso de entrenamiento y comprobar si está aprendiendo correctamente la red. Este error se calcula aplicando la expresión matemática 6.8.

$$ep^2 = \frac{1}{2} \cdot \sum_{k=1}^s \delta_k^2 \quad (6.8)$$

donde,

- ep^2 es el error cuadrático medio para cada patrón de entrada

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO- REOLÓGICO UTILIZANDO REDES NEURONALES

Este proceso de cálculo del error se realiza continuamente hasta que terminan los patrones de entrenamiento (r). El objetivo de la red es minimizar el error cuadrático medio total que se calcula de la siguiente manera:

$$e^2 = \sum_{p=1}^r ep^2 \quad (6.9)$$

donde,

- e^2 es el error cuadrático medio de toda la red

En la red neuronal se crea un espacio de “ n ” dimensiones que es generado por el error cometido, siendo “ n ” el número de pesos de conexión de red. Evaluando el gradiente del error en un punto de dicha superficie se obtiene la dirección en la cual el error tiene un mayor crecimiento. Debe tomarse la dirección negativa de crecimiento del error, ya que el objetivo de la red es minimizarlo. Para ello se utiliza la expresión 6.10.

$$W_{k+1} = W_k - \alpha \cdot \nabla ep^2 \quad (6.10)$$

El gradiente negativo del error cuadrático medio total se calcula como la derivada del error con respecto a los pesos de la red. En la ecuación 6.11 se calcula el gradiente negativo del error en la capa de salida con respecto a los pesos.

$$-\frac{\partial ep^2}{\partial W_{kj}^s} = -\frac{\partial}{\partial W_{kj}^s} \cdot \left(\frac{1}{2} \sum_{k=1}^l t_k - a_k^s \right)^2 = t_k - a_k^s \cdot \frac{\partial a_k^s}{\partial W_{kj}^s} \quad (6.11)$$

donde,

- $\frac{\partial ep^2}{\partial W_{kj}^s}$ es la componente del gradiente del error con respecto a la neurona “ j ” de la capa oculta y la neurona de salida
- $\frac{\partial a_k^s}{\partial W_{kj}^s}$ es la derivada de la neurona “ k ” de la capa de salida con respecto al peso W_{kj}^s

Como el error no es una función explícita de los pesos de la red, para calcular $\frac{\partial ep^2}{\partial W_{kj}^s}$ hay que utilizar la regla de la cadena. Considerando las ecuaciones 6.4 y 6.5 se observa que la salida de la red a_k^s está explícitamente en función de n_k^s y que n_k^s además está en función de W_{kj}^s , de lo que se deduce la expresión 6.12.

$$\frac{\partial a_k^s}{\partial W_{kj}^s} = \frac{\partial a_k^s}{\partial n_k^s} \cdot \frac{\partial n_k^s}{\partial W_{kj}^s} \quad (6.12)$$

Sustituyendo la expresión 6.12 en la ecuación 6.11 se obtiene la 6.13.

$$-\frac{\partial ep^2}{\partial W_{kj}^s} = t_k - a_k^s \cdot \frac{\partial a_k^s}{\partial n_k^s} \cdot \frac{\partial n_k^s}{\partial W_{kj}^s} \quad (6.13)$$

donde,

- $\frac{\partial a_k^s}{\partial n_k^s}$ es la derivada de la entrada neta a la neurona “ k ” de la capa de salida respecto a los pesos de conexión entre las neuronas de la capa oculta y la capa de salida

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO- REOLÓGICO UTILIZANDO REDES NEURONALES

- $\frac{\partial n_k^s}{\partial w_{kj}^s}$ es la derivada de la salida de la neurona “k” de la capa de salida con respecto a su entrada neta

Sustituyendo en la ecuación 6.13 las derivadas de las ecuaciones 6.4 y 6.5 se obtiene la expresión 6.14.

$$-\frac{\partial ep^2}{\partial w_{kj}^s} = t_k - a_k^s \cdot f^{s'} \cdot n_k^s \cdot a_j^o \quad (6.14)$$

Como se observa en la expresión 6.14, es necesaria la derivada de la función de transferencia. Es por ello que una de las condiciones indispensables que esta función debe cumplir para aplicar el algoritmo *backpropagation* es que sea derivable y continua en todo su dominio. Como se explicó en la sección 6.2.3, las funciones más utilizadas son la función identidad, la función logística y la función tangente hiperbólica.

De la ecuación 6.14 se deduce la expresión para la “sensitividad de la capa de salida” que son los términos del error para esta capa y se calcula mediante la ecuación 6.15.

$$\delta_k^s = t_k - a_k^s \cdot f^{s'} \cdot n_k^s \quad (6.15)$$

El algoritmo se llama *backpropagation* porque el error se va propagando de manera inversa al funcionamiento natural de la red. Es decir, se encuentra el error desde las últimas capas hasta llegar a la capa de entrada, a partir de este error se modifican los pesos y las ganancias para conseguir minimizarlo. Una vez que se conoce el error en la capa de salida hay que calcular el error en la capa oculta aplicando la expresión 6.16.

$$-\frac{\partial ep^2}{\partial w_{ji}^o} = -\frac{\partial}{\partial w_{ji}^o} \cdot \left(\frac{1}{2} \cdot \sum_{k=1}^l (t_k - a_k^s)^2 \right) = \sum_{k=1}^l (t_k - a_k^s) \cdot \frac{\partial a_k^s}{\partial w_{ji}^o} \quad (6.16)$$

Para calcular el último término de esta expresión es necesario aplicar la regla de la cadena varias veces ya que, como ocurría en la expresión 6.12, la salida de la red no es función explícita de los pesos entre la capa de entrada y la capa oculta (ver ecuación 6.17).

$$\frac{\partial a_k^s}{\partial w_{ji}^o} = \frac{\partial a_k^s}{\partial n_k^s} \cdot \frac{\partial n_k^s}{\partial a_k^o} \cdot \frac{\partial a_k^o}{\partial n_j^o} \cdot \frac{\partial n_j^o}{\partial w_{ji}^o} \quad (6.17)$$

En la ecuación 6.17, todos los términos son derivadas con respecto de las variables de las que dependen explícitamente. Por lo tanto, sustituyendo la ecuación 6.17 en la 6.16 se obtiene la expresión 6.18.

$$-\frac{\partial ep^2}{\partial w_{ji}^o} = \sum_{k=1}^l (t_k - a_k^s) \cdot \frac{\partial a_k^s}{\partial n_k^s} \cdot \frac{\partial n_k^s}{\partial a_k^o} \cdot \frac{\partial a_k^o}{\partial n_j^o} \cdot \frac{\partial n_j^o}{\partial w_{ji}^o} \quad (6.18)$$

Tomando las derivadas de las ecuaciones 6.2, 6.3.6.4 y 6.5 y sustituyéndolas en la ecuación 6.18 se obtiene la expresión para calcular el gradiente del error en la capa oculta (ecuación 6.19).

$$-\frac{\partial ep^2}{\partial w_{ji}^o} = \sum_{k=1}^l (t_k - a_k^s) \cdot f^{s'} \cdot n_k^s \cdot W_{kj}^s \cdot f^{o'} \cdot n_j^o \cdot p_i \quad (6.19)$$

Reemplazando la ecuación 6.15 en la 6.19 se obtiene:

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO- REOLÓGICO UTILIZANDO REDES NEURONALES

$$-\frac{\partial ep^2}{\partial W_{ji}^o} = \sum_{k=1}^l \delta_k \cdot f^{s'} \cdot n_k^s \cdot W_{kj}^s \cdot f^{o'} \cdot n_j^o \cdot p_i \quad (6.20)$$

Al igual que para la capa de salida, se puede calcular para la capa oculta la “sensitividad de la capa oculta” aplicando la expresión 6.21.

$$\delta_j^o = f^{o'} \cdot n_j^o \cdot \sum_{k=1}^l \delta_k \cdot W_{kj}^s \quad (6.21)$$

Después de haber calculado el gradiente del error para cada capa se procede a actualizar los pesos de las conexiones. En primer lugar se actualizan los pesos y ganancias de la capa de la salida mediante las expresiones 6.22. Después se hace lo mismo con la capa oculta para actualizar sus pesos aplicando las ecuaciones 6.23.

$$W_{kj} \ t + 1 = W_{kj} \ t - 2 \cdot \alpha \cdot \delta_k^s \quad (6.22)$$

$$b_k \ t + 1 = b_k \ t - 2 \cdot \alpha \cdot \delta_k^s$$

$$W_{ji} \ t + 1 = W_{ji} \ t - 2 \cdot \alpha \cdot \delta_j^o \cdot p_i \quad (6.23)$$

$$b_j \ t + 1 = b_j \ t - 2 \cdot \alpha \cdot \delta_j^o$$

Se ha realizado el análisis del algoritmo *backpropagation* para una red con tres capas (ver figura 6.8). Si se quiere analizar para una red con más capas ocultas, las expresiones deben derivarse de la expresión 6.21, donde los términos dentro del sumatorio pertenecen a la capa inmediatamente superior. Este algoritmo es conocido como la regla *Delta generalizada*.

Como puede observarse en este análisis, el algoritmo *backpropagation* utiliza la misma técnica de aproximación en pasos descendientes que utiliza la regla *Least Mean Squared*. El único problema es calcular el gradiente, término indispensable en el cálculo de la sensitividad de las capas.

En la aplicación de este algoritmo es importante avanzar por la superficie de error con incrementos pequeños de los pesos. Esto se debe a que se tiene una información local de la superficie y no se sabe si se está cerca o no de un mínimo, utilizando incrementos grandes se corre el riesgo de pasar por encima del punto mínimo. Utilizando incrementos pequeños, se tarda más en alcanzar el mínimo pero se evita que esto ocurra (ver figura 6.9).

Elegir un incremento adecuado influye en la velocidad de convergencia del algoritmo, la cual se controla a través del factor de entrenamiento que suele estar entre 0 y 1. Por lo general, se comienza con un valor pequeño del factor de entrenamiento para asegurarse que la red llega a una solución. Tomar un valor pequeño significa que la red realiza muchas iteraciones, tomando un valor grande se avanza rápidamente por la superficie de error y se corre el riesgo, como se ha dicho antes, de pasar por encima del valor mínimo. Cuando esto ocurre se puede permanecer oscilando alrededor del valor mínimo pero sin llegar a alcanzarlo.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

A medida que disminuye el error es recomendable ir modificando el valor del factor de entrenamiento para conseguir una rápida convergencia, teniendo precaución de no producir en los pesos cambios muy grandes y no poder alcanzar el mínimo. Como se observa en la figura 6.9, la convergencia puede producirse hacia uno de los mínimos locales y no hacia el mínimo global.



Figura 6.9: Representación del error en una RNA [32]

Este procedimiento matemático no asegura alcanzar un mínimo global, puede alcanzarse un mínimo local. Cuando la red alcanza un mínimo, ya sea local o global, el aprendizaje se detiene aunque el valor del error siga siendo alto. En este caso es el supervisor el que debe determinar si la solución es válida o no, ya que un mínimo local puede dar un valor aceptable del error pues puede estar próximo al mínimo global.

6.4. VALIDACIÓN DE UNA RNA

El último paso a seguir en el aprendizaje de una RNA es su correspondiente validación. Cuando el entrenamiento finaliza, el valor de los pesos de las conexiones permanece invariable. Para comprobar que la red ha aprendido correctamente es necesario introducir un nuevo conjunto de datos denominado “datos de validación” para comprobar si la red es capaz de resolver problemas para los que sido entrenada. Este conjunto de datos tiene los valores de entrada y, como se conocen las salidas deseadas, se comparan con las salidas de la red para ver si coinciden y, por lo tanto, si la red ha aprendido correctamente [31].

6.5. JAVANNS

JavaNNS es el software de redes neuronales artificiales utilizado en este Trabajo de Fin de Grado. JavaNNS (*Java Neural Network Simulation*) es un software desarrollado por la Universidad de Tübingen (Stuttgart- Alemania). Es la continuación del simulador de redes neuronales SNNS (*Stuttgart Neural Network Simulation*) pero utilizando una interfaz Java. Esta versión es mucho más sencilla e intuitiva que su predecesora, pudiendo realizar prácticamente las mismas aplicaciones que ésta a excepción de aquellas más complicadas. Sin embargo, para este proyecto la versión Java es suficiente.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

Este software permite tanto la creación como el entrenamiento y validación de redes neuronales. En primer lugar es necesario haber recopilado datos suficientes para entrenar y para validar la red, para lo cual se necesitarán dos ficheros independientes, uno de entrenamiento y otro de validación. Por otro lado se tiene que crear la red, sabiendo el número de neuronas de entrada y de salida que se necesitan es bastante sencillo realizarlo. Una vez que se tienen los datos preparados y la red creada, puede comenzar el entrenamiento, analizando la gráfica de error y variando el factor de entrenamiento cuando sea conveniente.

En el ANEXO A de este Trabajo de Fin de Grado se ha realizado un pequeño tutorial en el cual se explica el modo de utilización de este software. Se explica de manera básica la creación de redes, su entrenamiento y validación [33].

6.6. APLICACIONES DE LAS RNA

Las RNA tienen muchas aplicaciones, tanto comerciales como militares. Se pueden crear en un periodo de tiempo bastante razonable y son mucho más potentes que otras tecnologías. Pueden implementarse mediante hardware presentando una alta tolerancia a fallos y permitiendo el procesamiento de datos en paralelo, lo cual es muy útil para la inserción de bajo coste de las redes neuronales en programas ya existentes.

Existen diferentes programas de redes neuronales, cada uno de los cuales tiene su propia aplicación. Algunas de las aplicaciones más importantes son las siguientes:

- *Biología*: aprender más acerca del cerebro o modelos de retina.
- *Empresa*: reconocimiento de caracteres escritos, explotación de bases de datos u optimización de plazas y horarios en líneas de vuelo.
- *Finanzas*: previsión de la evolución de los precios, identificación de falsificaciones o análisis de firmas.
- *Manufacturación*: control de producción en líneas de procesos, control de calidad o robots automatizados y sistemas de control.
- *Medicina*: monitorización en cirugía, entendimiento de la causa de ataques cardíacos o predicción de reacciones adversas en los medicamentos.
- *Medio ambiente*: analizar tendencias y patrones o previsión del tiempo.
- *Militares*: optimización de recursos, creación de armas inteligentes o reconocimiento y seguimiento en el tiro al blanco.

Estas son algunas de las aplicaciones más importantes de las RNA aunque existen muchas más. La mayoría consisten en el reconocimiento de patrones y clasificación aunque actualmente está creciendo el uso de RNA como sistemas de control. La ventaja de las RNA es el procesamiento en paralelo, adaptativo y no lineal [31].

CAPÍTULO 7

RESULTADOS

7.1. INTRODUCCIÓN

La última parte de este Trabajo de Fin de Grado consiste en el modelado experimental de un amortiguador MR de sentido inverso utilizando el software de redes neuronales JavaNNS.

A partir de una serie de análisis en el laboratorio sobre un amortiguador MR se ha recogido una gran cantidad de datos que han sido extraídos en un Hoja Excel. Como se trata de un modelo inverso (ver figura 7.1), los datos de entrada medidos corresponden al desplazamiento de la carrera del amortiguador, a la velocidad, a la fuerza de amortiguación y a la frecuencia. En cuanto a la salida, se mide la corriente. La diferencia de un modelo inverso con respecto a un modelo directo, es que en el inverso se introduce la fuerza de amortiguación como entrada de la red y la salida que se quiere obtener es la corriente. Esta corriente es la que el sistema necesita para poder proporcionar dicha fuerza de amortiguación. En cuanto al modelo directo, la entrada introducida es la corriente y la salida obtenida la fuerza. El desplazamiento, la velocidad y la frecuencia son datos de entrada en ambos casos. En la figura 7.1 se muestra un esquema simplificado de estos dos modelos, con sus entradas y salida adecuada.

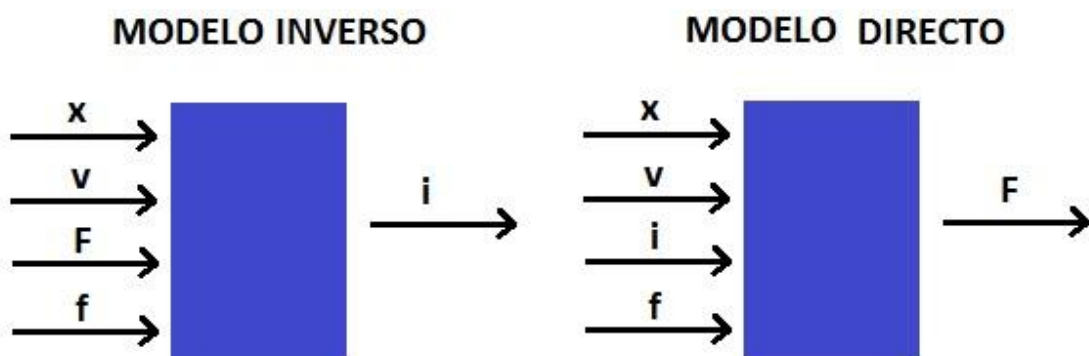


Figura 7.1: Esquema de un modelo directo y un modelo inverso de un amortiguador MR

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

Se han recogido un total de 179811 conjuntos de datos, cada conjunto de datos está formado por un valor de desplazamiento, velocidad, fuerza, frecuencia y su correspondiente corriente, es decir, que cada conjunto de datos está formado a su vez por cinco datos (cuatro de entrada y uno de salida). Ante este gran volumen de información es necesario hacer una selección, se deben elegir unos datos para realizar el entrenamiento de la red y otros para realizar la validación (ver sección 7.2).

En este Trabajo de Fin de Grado se va a analizar un modelo inverso de amortiguador MR, para ello, se va a utilizar el software JavaNNS de redes neuronales y un proceso de entrenamiento supervisado utilizando la regla *backpropagation* explicada en la sección 6.3.3.

7.2. PATRONES DE ENTRENAMIENTO Y VALIDACIÓN

El primer paso antes de empezar con el software es depurar y seleccionar los datos que se van a utilizar. Se tiene un total de 899055 datos, 179811 filas con cinco columnas correspondientes a los datos de entrada (desplazamiento, velocidad, fuerza y frecuencia) y un dato de salida (corriente). Las unidades en las que se han medido estas variables se muestran en la tabla 7.1.

VARIABLE	DESPLAZAMIENTO	VELOCIDAD	FUERZA	FRECUENCIA	CORRIENTE
UNIDAD	mm	m/s	kN	Hz	A

Tabla 7.1: Unidades de los datos recogidos

Para poder introducir los datos en el programa es necesario crear dos ficheros, uno para los datos de entrenamiento y otro para los de validación. El primer fichero se utiliza para el aprendizaje de la red y el segundo para la comprobación de que ha aprendido correctamente. Es recomendable que el conjunto de entrenamiento contenga una gran cantidad de datos mientras que el de validación puede contener menos.

Hay que tener en cuenta que para el aprendizaje de la RNA se va a utilizar una función de activación derivable y que trabaja en un rango de $[-1,1]$, por lo que, se deben normalizar los datos entre estos valores para poder introducirlos en JavaNNS. Para normalizar los datos se aplican las siguientes ecuaciones, según sea el dato:

- 1) Desplazamiento normalizado: $x_{i,normalizado} = \frac{x_i}{x_{máx}}$
- 2) Velocidad normalizada: $v_{i,normalizada} = \frac{v_i}{v_{máx}}$
- 3) Fuerza normalizada: $F_{i,normalizada} = \frac{F_i}{F_{máx}}$
- 4) Frecuencia normalizada: $f_{i,normalizada} = \frac{f_i}{f_{máx}}$
- 5) Corriente normalizada: $i_{i,normalizada} = \frac{i_i}{i_{máx}}$

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

Una vez normalizados los datos entre [-1 y 1] se procede a la selección de los patrones de entrenamiento y validación. En este caso se han escogido 2569 conjuntos de datos (12845 datos en total) para el patrón de entrenamiento y 644 conjuntos de datos (3220 en total) para el patrón de validación. Estos datos se han extraído de la Hoja Excel y se han creado dos ficheros de texto independientes para entrenamiento y otro para validación. Estos ficheros de texto deben tener un encabezado específico para que el programa JavaNNS sea capaz de reconocer los patrones. En este encabezado (ver figuras 7.2 y 7.3) deben figurar el número de entradas *nº of inputs*- (4 en este caso), el número de datos de salida *nº of outputs*- (1 en este caso) y el número de conjuntos de datos introducidos *nº of patterns*- (2569 para el caso del patrón de entrenamiento y 644 para el patrón de validación).

En la figura 7.2 se muestra un fragmento del fichero de texto creado para el patrón de entrenamiento. En la imagen de la izquierda se observan los datos sin normalizar y en la parte de la derecha los datos normalizados, es decir, el fichero que se utilizará para introducir en el software.

SNNS pattern definition file v4.2 generated at Fri Sep 13 11:40:34 2013					SNNS pattern definition file v4.2 generated at Fri Sep 13 11:40:34 2013				
No. of patterns : 2569 No. of input units : 4 No. of output units : 1					No. of patterns : 2569 No. of input units : 4 No. of output units : 1				
-1.16994	0.00000	0.00000	0.50000	0.00000	-0.07197	0.00000	0.00000	0.05556	0.00000
-4.67976	-0.04961	-0.10791	0.50000	0.00000	-0.28787	-0.04769	-0.03994	0.05556	0.00000
-7.99289	-0.04575	-0.11160	0.50000	0.00000	-0.49168	-0.04398	-0.04130	0.05556	0.00000
-10.86776	-0.03923	-0.12087	0.50000	0.00000	-0.66852	-0.03771	-0.04474	0.05556	0.00000
-13.12689	-0.03037	-0.12282	0.50000	0.00000	-0.80749	-0.02919	-0.04546	0.05556	0.00000
-14.77385	-0.02075	-0.12738	0.50000	0.00000	-0.90880	-0.01995	-0.04714	0.05556	0.00000
-15.68590	-0.01070	-0.11751	0.50000	0.00000	-0.96490	-0.01029	-0.04349	0.05556	0.00000
-15.94702	-0.00090	-0.11238	0.50000	0.00000	-0.98097	-0.00087	-0.04159	0.05556	0.00000
-15.33468	0.01223	0.03447	0.50000	0.00000	-0.94330	0.01176	0.01276	0.05556	0.00000
-13.83273	0.02372	0.11478	0.50000	0.00000	-0.85091	0.02280	0.04248	0.05556	0.00000
-11.64449	0.03372	0.12306	0.50000	0.00000	-0.71630	0.03241	0.04555	0.05556	0.00000
-8.85666	0.04140	0.12600	0.50000	0.00000	-0.54481	0.03980	0.04663	0.05556	0.00000
-5.63686	0.04819	0.13548	0.50000	0.00000	-0.34675	0.04632	0.05014	0.05556	0.00000
-2.11752	0.05117	0.13920	0.50000	0.00000	-0.13026	0.04919	0.05152	0.05556	0.00000
1.50178	0.05168	0.14775	0.50000	0.00000	0.09238	0.04968	0.05468	0.05556	0.00000
5.01483	0.04956	0.15027	0.50000	0.00000	0.30848	0.04764	0.05362	0.05556	0.00000
8.28614	0.04553	0.16401	0.50000	0.00000	0.50971	0.04377	0.06070	0.05556	0.00000
11.05459	0.03848	0.16086	0.50000	0.00000	0.68001	0.03699	0.05954	0.05556	0.00000
13.35894	0.02929	0.16569	0.50000	0.00000	0.82176	0.02912	0.06132	0.05556	0.00000
14.92855	0.02052	0.16464	0.50000	0.00000	0.91832	0.01373	0.06094	0.05556	0.00000
15.83091	0.01014	0.16464	0.50000	0.00000	0.97383	0.00975	0.06094	0.05556	0.00000
15.98238	-0.00074	0.12726	0.50000	0.00000	0.98314	-0.00071	0.04710	0.05556	0.00000
15.30238	-0.01333	0.10604	0.50000	0.00000	0.94131	-0.01281	0.02241	0.05556	0.00000
13.76184	-0.02443	-0.06855	0.50000	0.00000	0.84655	-0.02348	-0.02537	0.05556	0.00000
11.54436	-0.03447	-0.07626	0.50000	0.00000	0.71014	-0.03314	-0.02822	0.05556	0.00000

Figura 7.2: Patrón de entrenamiento sin normalizar (izquierda) y normalizado (derecha)

En la figura 7.3 se muestran, al igual que en la figura 7.2, un fragmento del fichero de texto correspondiente a los datos de validación. En la imagen de la izquierda se muestran los datos sin normalizar y en la de la derecha los datos normalizados y definitivos que se utilizarán en el análisis.

SNNS pattern definition file v4.2 generated at Fri Sep 13 11:40:34 2013					SNNS pattern definition file v4.2 generated at Fri Sep 13 11:40:34 2013				
No. of patterns : 644 No. of input units : 4 No. of output units : 1					No. of patterns : 644 No. of input units : 4 No. of output units : 1				
-4.58949	-0.04962	-0.10755	0.50000	0.00000	-0.28277	-0.04847	-0.04059	0.05556	0.00000
-10.79364	-0.03948	-0.12048	0.50000	0.00000	-0.90807	-0.02055	-0.04805	0.05556	0.00000
-14.73849	-0.02104	-0.12732	0.50000	0.00000	-0.85246	0.02302	0.04330	0.05556	0.00000
-15.93410	-0.00118	-0.11223	0.50000	0.00000	-0.13206	0.04987	0.05260	0.05556	0.00000
-13.83596	0.02356	0.11475	0.50000	0.00000	0.67931	0.03756	0.06071	0.05556	0.00000
-8.86635	0.04118	0.12591	0.50000	0.00000	0.98550	-0.00078	0.04845	0.05556	0.00000
-2.14336	0.05105	0.13938	0.50000	0.00000	0.53832	-0.04188	-0.03126	0.05556	0.00000
4.95686	0.04946	0.15018	0.50000	0.00000	-0.59353	0.07654	0.05122	0.11111	0.00000
11.02552	0.03845	0.16089	0.50000	0.00000	0.89496	0.04917	0.06905	0.11111	0.00000
14.94147	0.02050	0.16476	0.50000	0.00000	0.17514	-0.09716	-0.04542	0.11111	0.00000
15.99530	-0.00080	0.12840	0.50000	0.00000	-0.97637	-0.00850	-0.03973	0.11111	0.00000
13.80043	-0.02439	-0.06825	0.50000	0.00000	0.28098	0.09812	0.06650	0.11111	0.00000
8.73732	-0.04287	-0.08283	0.50000	0.00000	0.87510	-0.03740	-0.02836	0.11111	0.00000
1.93375	-0.05108	-0.10218	0.50000	0.00000	-0.66660	-0.07818	-0.04785	0.11111	0.00000
-9.63339	0.07835	0.13572	1.00000	0.00000	0.54746	0.07797	0.05109	0.11111	0.00000
4.10601	0.10275	0.17658	1.00000	0.00000	-0.67812	0.10062	0.05162	0.16667	0.00000
14.52565	0.05033	0.18297	1.00000	0.00000	0.93169	-0.01881	-0.01062	0.16667	0.00000
14.42569	-0.03575	-0.07551	1.00000	0.00000	-0.97498	-0.03210	-0.04416	0.16667	0.00000
2.84257	-0.09046	-0.12036	1.00000	0.00000	0.86566	0.08873	0.07266	0.16667	0.00000
-10.48424	-0.08089	-0.12429	1.00000	0.00000	-0.60823	-0.13152	-0.05752	0.16667	0.00000
-15.84706	-0.00870	-0.10527	1.00000	0.00000	0.23033	0.15059	0.07286	0.16667	0.00000
-9.24987	0.07946	0.13176	1.00000	0.00000	0.19281	-0.14524	-0.05452	0.16667	0.00000
4.56042	0.10044	0.17622	1.00000	0.00000	-0.79170	-0.14679	-0.06098	0.22222	0.00000
14.67389	0.04774	0.17850	1.00000	0.00000	0.96227	0.07025	0.07052	0.22222	0.00000
14.20333	-0.03828	-0.07515	1.00000	0.00000	-0.95175	0.00343	-0.03991	0.22222	0.00000

Figura 7.3: Patrón de validación sin normalizar (izquierda) y normalizado (derecha)

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

Como puede verse, el encabezado para el patrón de entrenamiento y para el patrón de validación es el mismo y solamente varía el *nº of patterns*, es decir, el número de conjuntos de datos. Además del encabezado, la manera de introducir los datos es en columnas. Cada columna son los datos de una de las variables, en primer lugar se introducen los datos de entrada (cuatro primeras columnas) y, después los datos de salida (última columna). En este caso tenemos cinco columnas, la primera corresponde al desplazamiento, la segunda a la velocidad, la tercera a la fuerza, la cuarta a la frecuencia y la quinta a la corriente.

Una última cuestión de gran importancia a la hora de escoger los datos es que deben seleccionarse de manera aleatoria y deben cubrir todo el rango de valores. Es decir, en este caso, se han medido valores de desplazamiento, velocidad y fuerza para corrientes que toman valores de 0 A, 0.2 A, 0.4 A, 0.6 A y 0.8 A. En cuanto a la frecuencia, va variando para cada valor de corriente desde 0.5 Hz a 9 Hz aumentando de 0.5 en 0.5 Hz. Por lo tanto, los datos escogidos de entrenamiento y validación deben de tener valores de corriente y de frecuencia que cubran todas estas posibilidades.

El último paso para introducir los datos en JavaNNS es crear un archivo .pat como se explica en el ANEXO A (sección A.4).

7.3. TIPOLOGÍA DE LA RED NEURONAL

Una vez seleccionados, normalizados y preparados los datos de entrenamiento y validación, hay que pensar en la arquitectura de la red neuronal. Una red neuronal tiene una capa de entrada, tantas capas ocultas como se necesite y una capa de salida (ver sección 6.2.1). La tipología de las redes que se van a utilizar en este análisis es la siguiente:

- 1) Capa de entrada: la capa de entrada está formada por los datos de entrada y tiene tantas neuronas como datos se introduzcan. En este caso se tienen cuatro datos de entrada (desplazamiento, velocidad, fuerza y frecuencia), por lo que, la capa de entrada tendrá 4 neuronas.
- 2) Capa oculta: el aprendizaje de la red neuronal y el cálculo del error va a estar determinado en gran medida por el número de capas ocultas y el número de neuronas que contenga cada capa. Para cada problema existe una red óptima, no existe un método para predecir cuál va a ser el mejor número de capas ocultas para cada problema, depende de la experiencia del diseñador. En este análisis se va a ir variando el número de capas ocultas y el número de neuronas en cada capa hasta encontrar la mejor tipología de red para estos datos.
- 3) Capa de salida: la capa de salida contiene los datos de salida, por ello, en este caso solamente se tiene una neurona en esta capa que corresponde a la corriente.

Las redes neuronales utilizadas se van a denominar de la siguiente manera: E-O-...-O-S. La letra “E” corresponde al número de neuronas en la capa de entrada (en este caso será siempre 4), la letra “O” corresponde al número de neuronas en la/s capa/s oculta/s (este número es el que va a ir variando) y la letra “S” se refiere al número de neuronas en la capa de salida (será siempre 1). Por lo tanto, todas las redes se denominarán como: 4-O-...-O-1. En la tabla 7.2 se muestra un esquema de las redes analizadas.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

RED	CAPA DE ENTRADA		CAPA OCULTA		CAPA DE SALIDA	
	Nº Capas	Nº Neuronas	Nº Capas	Nº Neuronas	Nº Capas	Nº Neuronas
4-10-1	1	4	1	10	1	1
4-20-1	1	4	1	20	1	1
4-30-1	1	4	1	30	1	1
4-20-20-1	1	4	2	20	1	1
4-30-30-1	1	4	2	30	1	1
4-25-25-25-1	1	4	3	25	1	1

Tabla 7.2: Resumen de redes utilizadas

Como se observa en la tabla, la metodología utilizada ha sido determinar en primer lugar si era mejor tener más o menos neuronas en la capa oculta y, después, ver si añadiendo más capas ocultas se conseguían mejores resultados.

7.4. FUNCIÓN DE ACTIVACIÓN

La función de activación (ver sección 6.2.3) debe ser una función continua y derivable en todo su dominio. La función utilizada en la capa de entrada se ha variado para ver con cuál se obtenían mejores resultados, la función utilizada en las capas ocultas ha sido la función logística y la función de la capa de salida la función identidad. En la tabla 7.3 se muestra un resumen de las funciones utilizadas en cada capa.

CAPA	ENTRADA	OCULTA	SALIDA
FUNCIÓN	Sigmoidal	Logística	Identidad
	Tangente hiperbólica		

Tabla 7.3: Resumen funciones de activación de cada capa

7.5. PESOS SINÁPTICOS

Los pesos sinápticos entre las conexiones de las neuronas se deben ir variando a medida que avanza el entrenamiento para conseguir minimizar el error. Al principio del entrenamiento se escogen unos valores para los pesos y a lo largo del proceso JavaNNS va adaptándolos. En el panel del control, antes de empezar el proceso de entrenamiento, se inicializan los pesos. En este caso se ha escogido el método recomendado de inicialización *random weights*, el cual asigna valores aleatorios a los pesos.

El software permite la visualización de la gráfica de los pesos desde el momento de la inicialización como a lo largo de todo el entrenamiento (ver sección del anexo A.7).

7.6. FACTOR DE ENTRENAMIENTO

El factor de entrenamiento es uno de los parámetros más importantes durante el entrenamiento y aprendizaje de una RNA. Se suele representar con la letra griega “ α ” o “ η ” (en

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

este Trabajo se representa con “ η ”). Durante el entrenamiento se va variando para ajustar los pesos de las conexiones y conseguir minimizar el error.

En cada caso debe analizarse cuál es la mejor manera de proceder para variar este factor. Sin embargo, lo más común es empezar el entrenamiento con un factor de 0.2 y mantenerlo mientras el error vaya disminuyendo. Cuando el error se estabiliza y ya no disminuye más, se procede a disminuir el factor de entrenamiento para que el error vuelva a disminuir. Al estabilizarse de nuevo el error, se vuelve a disminuir el factor y así sucesivamente. Lo más adecuado es realizar disminuciones pequeñas del factor de entrenamiento o factor de aprendizaje ya que si no se corre el riesgo de no alcanzar el mínimo error (ver sección 6.3.2). Para saber cuándo el error se ha estabilizado se utiliza la gráfica de error que permite visualizar JavaNNS (ver sección 7.7).

7.7. GRÁFICA DE ERROR

La gráfica de error es muy útil durante el entrenamiento de la red. No influye en los resultados, es una herramienta que sirve al supervisor para realizar de una manera correcta el aprendizaje. Al inicio del entrenamiento debe abrirse la pantalla que muestra esta gráfica, aparecerá en blanco. Durante el entrenamiento aparecen dos líneas que van evolucionando a lo largo de las iteraciones o ciclos que se producen en el proceso. Una de las líneas indica el error del patrón de entrenamiento (línea negra) y otra muestra el error del patrón de validación (línea rosa). Lo que se quiere es conseguir que estos errores sean lo más pequeños posibles. Para ello, cuando en la gráfica se observa que las líneas se vuelven horizontales significa que el error permanece constante y es el momento de disminuir el factor de entrenamiento.

En la gráfica de error pueden visualizarse tres tipos diferentes de errores; la suma de los cuadrados de los errores, el error cuadrático medio y la raíz del error cuadrático medio. En este trabajo se van a analizar los resultados utilizando el error cuadrático medio.

7.8. PROCESO DE APRENDIZAJE

En esta sección se van a analizar distintas redes para conseguir establecer cuál es la mejor red para utilizar con estos datos. Una primera parte del análisis consiste en determinar si es mejor utilizar como función de activación de la capa de entrada la función tangente hiperbólica o la función sigmodial. Al mismo tiempo que este análisis, se analiza si es mejor añadir neuronas en la capa oculta o no. La segunda parte del análisis consiste en añadir capas ocultas para ver si de esta manera se alcanzan mejores resultados, es decir, si se consigue un error más pequeño. El algoritmo de aprendizaje que se utiliza en todo momento es la regla *backpropagation* (ver sección 6.3.3).

7.8.1. RED 4-10-1

La primera red que se ha analizado tiene 4 neuronas en la capa de entrada, 10 neuronas en la única capa oculta que tiene y 1 neurona en la capa de salida. En este caso se van a realizar

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

dos análisis con esta red, un primer análisis en el que la capa de entrada tiene como función de activación la función tangente hiperbólica y un segundo en el que se utiliza la función sigmoideal. En resumen, las características de esta red son las siguientes:

- Capa de entrada: una capa de entrada con 4 neuronas.
- Capa oculta: una sola capa oculta con 10 neuronas.
- Capa de salida: una capa de salida con 1 neurona.
- Función de activación: tangente hiperbólica o sigmoideal.

En la figura 7.4 se muestra la tipología de esta red sin entrenar.

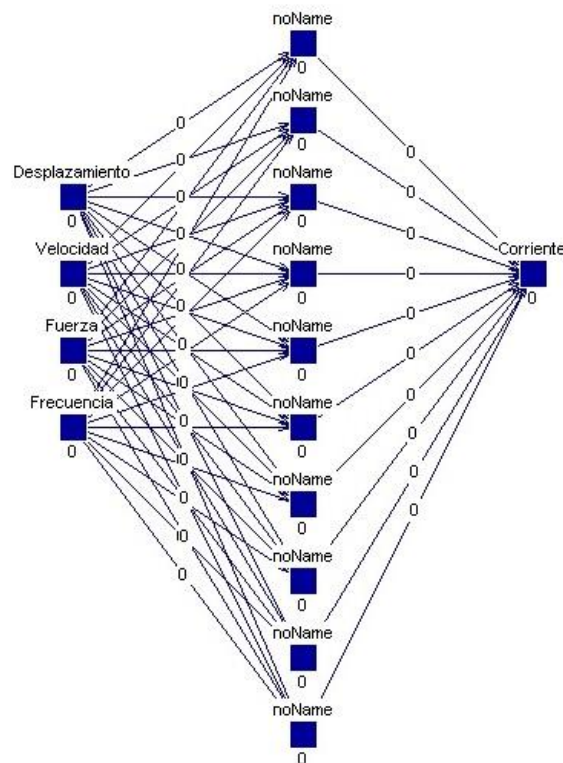


Figura 7.4 Red 4-10-1 sin entrenar

- 1) Función de activación tangente hiperbólica: El primer análisis que se ha realizado es utilizando la función de activación tangente hiperbólica. Una vez que se inicializan los pesos en el panel de control (ver ANEXO A- sección A.5) se procede a empezar el aprendizaje.

Se ha empezado utilizando un factor de entrenamiento de valor 0.2. Observando la gráfica de error, se ha disminuido a 0.1 cuando el error se ha estabilizado, luego a 0.01 y, por último a 0.001. Como puede verse en la figura 7.5, los primeros cambios del factor de entrenamiento producen “grandes” saltos del error pero el último cambio apenas se aprecia. Por eso, una vez que se ha estabilizado el error con un factor de 0.001 se ha considerado que el aprendizaje ha finalizado, con esta red no se puede conseguir un error menor.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

En la gráfica de error que se muestra en la figura 7.5 aparecen dos curvas, una rosa y otra negra. La curva negra muestra el error del patrón de entrenamiento y la curva rosa del patrón de validación. El de validación es mucho más pequeño que el de entrenamiento ya que el volumen de datos a analizar es mucho menor. Por este mismo motivo, los “saltos” que se producen al variar el factor de entrenamiento son también menores en la curva de validación.




Figura 7.5: Gráfica de error red 4-10-1 con función tangente hiperbólica

En la gráfica de error no se puede ver exactamente el valor del error cometido, por eso, durante el aprendizaje debe abrirse la ventana “log” (ver ANEXO A- sección A.8). En esta ventana van apareciendo los valores de los errores de validación y entrenamiento cada cierto número de ciclos. La figura 7.6 muestra un fragmento de esta ventana.

La imagen muestra una ventana de software llamada 'JavaNNS' con una pestaña 'Log'. La ventana muestra una tabla de valores de error (MSE) para los pasos 45,000 a 118,000. La tabla tiene tres columnas: 'Step', 'MSE' y 'validation'. Los valores de error de entrenamiento (MSE) disminuyen gradualmente desde 0.05740119507594138 hasta 0.047781495858423458. Los valores de error de validación (validation) también disminuyen gradualmente desde 0.015434573155752621 hasta 0.012664874888354946.

Step	MSE	validation
Step 45000	0.05740119507594138	0.015434573155752621
Step 46000	0.05669132967172943	0.019128786110729906
Step 47000	0.05633091778488633	0.014436314565054379
Step 48000	0.056678243222443954	0.014311081134014247
Step 49000	0.056638297086917096	0.013811383928571428
Step 50000	0.056797270449051945	0.013634324814221874
Step 51000	0.05258767501167629	0.01805050624823719
Step 54000	0.05260975169356465	0.013173962231748593
Step 57000	0.053111544306974234	0.01350633105876283
Step 60000	0.05221438555984023	0.013815881302638083
Step 63000	0.05222579411097935	0.013013074116677232
Step 66000	0.05261517163389218	0.013048312678840589
Step 69000	0.051931019895555436	0.012988734689558514
Step 72000	0.052767587744671364	0.014612486643820815
Step 75000	0.052079905634341034	0.013704282156428936
Step 78000	0.05242732148733198	0.012933417136624733
Step 82000	0.049044443213421364	0.012956246085788893
Step 84000	0.04892056921254034	0.012685150933603758
Step 86000	0.048754606187713816	0.012792089711064878
Step 88000	0.048718413951234045	0.01300601485353079
Step 90000	0.04843530299500649	0.013318026287955528
Step 92000	0.04848257799326263	0.012726357264548354
Step 94000	0.04816413369978437	0.013007719324242254
Step 96000	0.048606407568321464	0.013021207003859999
Step 98000	0.04844185136119771	0.01290409461311672
Step 100000	0.04844871366986577	0.012709305153130004
Step 102000	0.04777744838189643	0.012749962184740149
Step 104000	0.0479118601876016	0.012749326895482792
Step 106000	0.04793679788245918	0.012747811974946016
Step 108000	0.04775660082420207	0.01276279880477166
Step 110000	0.04790096105255696	0.0127455581049001
Step 112000	0.04782754590052255	0.012733188475140874
Step 114000	0.0478926238065921	0.01271844798733729
Step 116000	0.047786893311494626	0.012784461797394368
Step 118000	0.04781495858423458	0.012664874888354946

Figura 7.6: Ventana “log” red 4-10-1 función tangente hiperbólica

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

En la tabla 7.4 se muestra un resumen del análisis realizado; el número de ciclos que se han desarrollado, el factor de entrenamiento o aprendizaje para cada grupo de ciclos y el error cuadrático medio producido en cada momento en el conjunto de entrenamiento y en el conjunto de validación. El error calculado corresponde a la corriente y, por tanto, sus unidades serán amperios.

RED 4-10-1 TANGENTE HIPERBÓLICA			
FACTOR DE ENTRENAMIENTO (η)	Nº DE CICLOS	ERROR CUADRÁTICO MEDIO (MSE)	
		ENTRENAMIENTO	VALIDACIÓN
0,2	50000	0,056797	0,013634
0,1	32000	0,049044	0,012956
0,01	18000	0,048448	0,012709
0,001	20000	0,047851	0,012668

Tabla 7.4: Red 4-10-1 tangente hiperbólica

- 2) Función de activación sigmoideal: En este caso, se analiza la red 4-10-1 pero utilizando como función de activación en la capa de entrada la función sigmoideal (ver sección 6.2.3). Se procede de la misma manera que en el apartado anterior para realizar el análisis, se inicializan los pesos y se va modificando el factor de entrenamiento (η). De hecho, el número de ciclos escogidos para cada η es el mismo que en la función de activación tangente hiperbólica para poder comparar mejor los resultados obtenidos.

En la gráfica de error de este análisis (ver figura 7.7), se ven los saltos al igual que en la figura 7.5 cuando se modifica el factor de aprendizaje.




Figura 7.7 Gráfica de error red 4-10-1 con función sigmoideal

De la misma manera que antes, a partir de la ventana “log” se obtienen los resultados exactos del error cuadrático medio (MSE) cometido durante en el entrenamiento. En la tabla 7.5 se resumen los resultados obtenidos.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO- REOLÓGICO UTILIZANDO REDES NEURONALES

RED 4-10-1 SIGMODIAL			
FACTOR DE ENTRENAMIENTO (η)	Nº DE CICLOS	ERROR CUADRÁTICO MEDIO (MSE)	
		ENTRENAMIENTO	VALIDACIÓN
0,2	50000	0,061036	0,012967
0,1	32000	0,048893	0,012504
0,01	18000	0,048654	0,012923
0,001	20000	0,048298	0,012474

Tabla 7.5: Red 4-10-1 sigmoidal

7.8.2. RED 4-20-1

La siguiente red que se ha analizado tiene 4 neuronas en la capa de entrada, 20 neuronas en la única capa oculta que tiene y 1 neurona en la capa de salida. Es decir, se han añadido 10 neuronas en la capa oculta con respecto a la red anterior, todo lo demás permanece igual. Al igual que en el análisis anterior se van a realizar dos análisis, uno utilizando la función de activación tangente hiperbólica y el otro con la función sigmoidal. En resumen, las características de esta red son las siguientes:

- Capa de entrada: una capa de entrada con 4 neuronas.
- Capa oculta: una sola capa oculta con 20 neuronas.
- Capa de salida: una capa de salida con 1 neurona.
- Función de activación: tangente hiperbólica o sigmoidal.

En la figura 7.8 se muestra la red analizada sin entrenar:

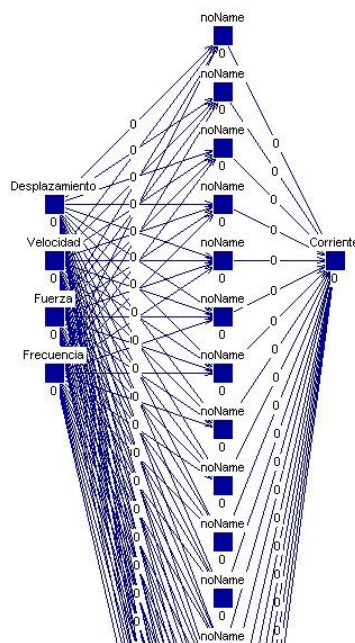


Figura 7.8: Red 4-20-1 sin entrenar

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

- 1) Función de activación tangente hiperbólica: El primer análisis que se ha realizado es utilizando la función de activación tangente hiperbólica. El análisis se hace de la misma manera que en la red 4-10-1 y se obtiene la gráfica de error mostrada en la figura 7.9.




Figura 7.9: Gráfica de error red 4-20-1 con función tangente hiperbólica

En este caso ocurre lo mismo que en la red 4-10-1, cuando se pasa del factor de entrenamiento 0,01 al 0,001 el salto es muy pequeño y apenas puede apreciarse gráficamente. Por eso cuando el error se ha estabilizado al cabo de, aproximadamente, 20000 ciclos, el aprendizaje se ha dado por finalizado. El número de ciclos es mayor que en la red anterior ya que al haber más neuronas es necesario un mayor análisis de ciclos para que se estabilice el error.

En la tabla 7.6 se muestra el resumen de los resultados obtenidos. Se puede observar que el error cometido en este caso es algo menor que en la red 4-10-1 en la que se utilizaba la misma función de activación (tangente hiperbólica). Por lo tanto se puede deducir que se van a conseguir mejores resultados al añadir neuronas en la capa oculta, aunque todavía no puede confirmarse esta teoría. El error calculado corresponde a la corriente y, por tanto, sus unidades serán amperios.

RED 4-20-1 TANGENTE HIPERBÓLICA			
FACTOR DE ENTRENAMIENTO (η)	Nº DE CICLOS	ERROR CUADRÁTICO MEDIO (MSE)	
		ENTRENAMIENTO	VALIDACIÓN
0,2	80000	0,044124	0,009995
0,1	50000	0,039656	0,010052
0,01	20000	0,036346	0,009856
0,001	20000	0,035602	0,009784

Tabla 7.6: Red 4-20-1 tangente hiperbólica

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

- 2) Función de activación sigmoideal: el segundo análisis de la red 4-20-1 que se realiza es el que utiliza la función de activación sigmoideal en la capa de entrada. Hay que tener en cuenta que es lo único que se modifica, el número de neuronas y el número de ciclos se mantiene constante.

La gráfica de error de la figura 7.10 correspondiente a este análisis muestra una gran semejanza a la figura 7.9. Los cambios que se producen al utilizar una función de activación u otra parecen ser mínimos.




Figura 7.10 Gráfica de error red 4-20-1 con función sigmoideal

Los resultados extraídos de la ventana “log” de este análisis se resumen en la tabla 7.7. Los valores numéricos del error indican que el aprendizaje de la red mejora a medida que se aumentan el número de neuronas en la capa oculta, que es la misma conclusión a la que se llegaba utilizando la función tangente hiperbólica. Además los resultados de utilizar una función de activación u otra, en principio, parecen ser prácticamente iguales. Es decir, la red aprende igual con ambas funciones de activación.

RED 4-20-1 SIGMODIAL			
FACTOR DE ENTRENAMIENTO (η)	Nº DE CICLOS	ERROR CUADRÁTICO MEDIO (MSE)	
		ENTRENAMIENTO	VALIDACIÓN
0,2	80000	0,044755	0,011516
0,1	50000	0,039978	0,009792
0,01	20000	0,036201	0,009770
0,001	20000	0,035687	0,009770

Tabla 7.7: Red 4-20-1 sigmoideal

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

7.8.3. RED 4-30-1

El siguiente análisis que se ha realizado ha sido en la red 4-30-1, es decir, 4 neuronas de entrada, 30 neuronas en la única capa oculta que hay y una neurona en la capa de salida correspondiente a la corriente. Por lo tanto, el único cambio que se ha realizado con respecto a la sección 7.8.2 es que se han añadido 10 neuronas a la capa oculta. Este es el último análisis en el cuál se van a utilizar dos funciones de activación distintas (sigmoideal o tangente hiperbólica), ya que, se va a sacar una conclusión de cuál es la mejor función para estos datos y ya solamente se realizará el análisis con la función óptima. En resumen, las características de esta red son las siguientes:

- Capa de entrada: una capa de entrada con 4 neuronas.
- Capa oculta: una sola capa oculta con 30 neuronas.
- Capa de salida: una capa de salida con 1 neurona.
- Función de activación: tangente hiperbólica o sigmoideal.

En la figura 7.11 se muestra la red analizada sin entrenar:




Figura 7.11: Red 4-30-1 sin entrenar

- 1) Función de activación tangente hiperbólica: Se empieza utilizando la función tangente hiperbólica como función de activación. Siguiendo el mismo proceso que en los análisis anteriores, se obtiene la gráfica de error correspondiente que se muestra en la figura 7.12.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES




Figura 7.12: Gráfica de error red 4-30-1 con función tangente hiperbólica

Los cambios realizados en el factor de entrenamiento son los mismos que antes; se empieza con un factor de 0,2 y se modifica hasta 0,001. Estos cambios se observan a modo de “saltos” en la gráfica, siendo más pronunciados los cambios en el error de entrenamiento (línea negra). El último “salto” o modificación del factor de entrenamiento, el cual corresponde al paso de $\eta=0,01$ a $\eta=0,001$, no se aprecia prácticamente en la gráfica y es por eso por lo que al estabilizarse el error se ha detenido el aprendizaje. De nuevo, el número de ciclos se ha incrementado ya que también han aumentado las neuronas en la capa oculta y el error tarda más en estabilizarse. En este caso el primer cambio del factor de entrenamiento se realiza a los 100000 ciclos, el segundo al pasar 50000 ciclos más y el último después de 20000 ciclos. Al ir disminuyendo el factor de entrenamiento son necesarios menos ciclos para conseguir la estabilización del error.

La tabla 7.8 muestra el resumen de los resultados obtenidos. Al igual que ocurría en el segundo análisis con respecto al primero, en este tercer análisis también disminuye ligeramente el valor del MSE con respecto a los otros análisis. La conclusión más clara que se puede obtener de estos resultados es que al añadir neuronas en la capa oculta se obtienen mejores resultados. Sin embargo, son necesarios aún más análisis ya que el valor del error obtenido es todavía elevado.

RED 4-30-1 TANGENTE HIPERBÓLICA			
FACTOR DE ENTRENAMIENTO (η)	Nº DE CICLOS	ERROR CUADRÁTICO MEDIO (MSE)	
		ENTRENAMIENTO	VALIDACIÓN
0,2	100000	0,044158	0,012701
0,1	50000	0,039107	0,009832
0,01	20000	0,036100	0,009252
0,001	20000	0,035759	0,009345

Tabla 7.8: Red 4-30-1 tangente hiperbólica

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

- 2) Función de activación sigmoideal: siguiendo el mismo orden que en los otros análisis, la segunda función de activación utilizada es la función sigmoideal. Recordando que lo único que se modifica es esta función, la tipología de la red y el número de ciclos se mantienen igual que en el análisis anterior, se procede a obtener los resultados.

En este nuevo análisis la gráfica de error obtenida (ver figura 7.13) es muy parecida a la obtenida utilizando la función tangente hiperbólica. Esto mismo ocurriría en los análisis con 10 neuronas en la capa oculta y con 20 neuronas.




Figura 7.13 Gráfica de error red 4-30-1 con función sigmoideal

Para realizar la tabla resumen 7.9 se utiliza la venta “log” (ver sección A.8) y se buscan los errores de entrenamiento y validación correspondiente. Es decir, se buscan los errores en los “saltos” producidos en la gráfica de error al variar el valor del factor de entrenamiento. Al igual que se observaba en la tabla 7.8 los errores tanto de validación como de entrenamiento han disminuido con respecto al análisis de la red 4-10-1 y 4-20-1 utilizando la función sigmoideal. Por lo tanto, ya se puede concluir que al ir aumentando las neuronas en la capa oculta el error va disminuyendo.

RED 4-30-1 SIGMODIAL			
FACTOR DE ENTRENAMIENTO (η)	Nº DE CICLOS	ERROR CUADRÁTICO MEDIO (MSE)	
		ENTRENAMIENTO	VALIDACIÓN
0,2	100000	0,036402	0,007582
0,1	50000	0,031669	0,007886
0,01	20000	0,027877	0,008014
0,001	20000	0,027445	0,008039

Tabla 7.9: Red 4-30-1 sigmoideal

La segunda conclusión a la que se llega tras estos análisis es que utilizar la función de activación sigmoideal produce valores del error un poco más pequeños que con la función tangente hiperbólica. Sin embargo, debido a que esta variación es mínima, se puede considerar

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

que no afecta a los resultados utilizar una función u otra. Por ello, a partir de ahora, se analizarán las redes utilizando solamente una función de activación. Se ha escogido la función sigmoideal.

7.8.4. RED 4-20-20-1

Una vez que se ha llegado a la conclusión de que es mejor añadir neuronas en la capa oculta para conseguir un mejor aprendizaje, se va a analizar el número óptimo de capas ocultas que debe haber. El primer análisis se realiza con la red 4-20-20-1, es decir, las capas de entradas y salida permanecen igual que en los análisis previos pero se ha añadido una capa oculta. Por lo tanto, en este caso se tienen dos capas ocultas con 20 neuronas cada una de ellas. Se ha escogido este número de neuronas aunque podría valer cualquiera, como en análisis anteriores se demostró que un número “alto” favorecía el aprendizaje, se van a analizar las redes con dos capas ocultas y con 20 neuronas en ambas capas ocultas y posteriormente se realizará con 30 neuronas en cada una de ellas. Realizar el análisis con más neuronas en las capas ocultas es de alta dificultad computacional y requiere demasiada potencia y tiempo de cálculo, pero los análisis realizados son suficientes para extraer las conclusiones pertinentes. Las características de la red 4-20-20-1 que se va a analizar se resumen a continuación, como se observa, en este caso solamente se utiliza la función sigmoideal para este análisis.

- Capa de entrada: una capa de entrada con 4 neuronas.
- Capa oculta: dos capas ocultas con 20 neuronas cada una.
- Capa de salida: una capa de salida con 1 neurona.
- Función de activación: sigmoideal.

En la figura 7.14 se muestra la red analizada sin entrenar:




Figura 7.14: Red 4-20-20-1 sin entrenar

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

El análisis se realiza siguiendo los mismos pasos que en ocasiones anteriores. Lo primero, se crea la red (ver figura 7.14) y se elige la función de activación de cada capa (sigmoideal para la capa de entrada, logística para las capas ocultas e identidad para la capa de salida). El siguiente paso importante es inicializar los pesos en el panel de control y abrir todas las pantallas que se van a necesitar (log, *weights* y *error graph*). Tras estos pasos ya puede empezar el aprendizaje. Se elige un factor de entrenamiento y el número de ciclos a analizar y se empieza a entrenar la red. Cuando se estabiliza el error se cambia el valor del factor de entrenamiento y así sucesivamente.

Los resultados obtenidos se muestran tanto en la gráfica de error como numéricamente en la ventana log (ver ANEXO sección A.8). En la figura 7.15 se muestra la gráfica de error correspondiente al análisis de la red 4-20-20-1.




Figura 7.15: Gráfica de error red 4-20-20-1 con función sigmoideal

La gráfica de error muestra una mayor variabilidad en el error de validación (línea rosa) con respecto a análisis anteriores ya que en el primer tramo sufre grandes variaciones y a partir de los 100000 ciclos tiende a aumentar ligeramente. En cuanto al error de entrenamiento (línea negra), sigue la misma tendencia que en los otros casos, disminuye al aumentar el número de ciclos y realiza un cambio o “salto” al modificar el factor de entrenamiento.

En la tabla 7.10 se muestra el resumen de resultados del análisis de la red 4-20-20-1. El MSE disminuye notablemente con respecto al análisis de la red 4-20-1, es decir, la misma red que en este caso pero con una capa oculta menos. Tanto los errores iniciales como los errores finales de validación y de entrenamiento son mucho más pequeños que en cualquiera de los análisis realizados en los que solamente había una capa oculta. Por lo tanto, se puede llegar a la conclusión de que para estos datos, la mejor tipología de red es con más de una capa oculta. El problema ahora es determinar si añadiendo más neuronas en cada capa oculta se siguen consiguiendo mejores resultados tal y como ocurría al añadir neuronas en la capa oculta cuando sólo se disponía de una capa.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO- REOLÓGICO UTILIZANDO REDES NEURONALES

RED 4-20-20-1 SIGMOIDAL			
FACTOR DE ENTRENAMIENTO (η)	Nº DE CICLOS	ERROR CUADRÁTICO MEDIO (MSE)	
		ENTRENAMIENTO	VALIDACIÓN
0,2	100000	0,005449	0,006376
0,1	71000	0,002449	0,006289
0,01	30000	0,002177	0,006526
0,001	13500	0,002172	0,006503

Tabla 7.10: Red 4-20-20-1 sigmoidal

7.8.5. RED 4-30-30-1

Después de todos los análisis realizados se ha llegado a la conclusión de que es algo mejor utilizar la función sigmoideal como función de activación y que es mejor tener por lo menos dos capas ocultas que una sola. El objetivo de analizar la red 4-30-30-1 es determinar si al añadir neuronas en las capas ocultas (cuando se tienen más de una capa oculta), los resultados mejoran o empeoran. Se realiza este análisis y se compara con el de la red 4-20-20-1 para poder sacar una conclusión. Las características correspondientes al análisis de esta red son las siguientes:

- Capa de entrada: una capa de entrada con 4 neuronas.
- Capa oculta: dos capas ocultas con 30 neuronas en cada capa.
- Capa de salida: una capa de salida con 1 neurona.
- Función de activación: sigmoideal.

En la figura 7.16 se muestra la red analizada sin entrenar:




Figura 7.16: Red 4-30-30-1 sin entrenar

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

El objetivo de analizar esta red es sacar alguna conclusión al compararla con la red 4-20-20-1, por eso, se han analizado los ciclos de la misma manera que en esta red. Es decir, para un factor de entrenamiento de 0,2 se ha entrenado a la red durante 100000 ciclos, para un factor de aprendizaje de 0,1 durante 70000, etc. El número de ciclos analizados para cada factor η se observa en la tabla 7.11.

En la figura 7. 17 se muestra la gráfica de error de este análisis. Como se observa, en este caso el error de validación (línea rosa) se va separando progresivamente del error de entrenamiento (línea negra) según se avanza en el número de ciclos. No ocurre como en el caso de la red 4-20-20-1 (ver figura 7. 15) en el que los errores se separan y luego se volvían a aproximar para luego separarse de nuevo.




Figura 7.17: Gráfica de error red 4-30-30-1 con función sigmoideal

Aunque en la gráfica no se observa, se han analizado 220000 ciclos al igual que en la red anterior. En la tabla 7.11 se muestra el resumen del análisis para todos los ciclos entrenados, como puede verse, los últimos 20000 ciclos (desde 200000 hasta 220000) corresponden al factor de entrenamiento de 0,001. Este último cambio de η no afecta prácticamente y por eso se ha omitido de la gráfica.

RED 4-30-30-1 SIGMOIDAL			
FACTOR DE ENTRENAMIENTO (η)	Nº DE CICLOS	ERROR CUADRÁTICO MEDIO (MSE)	
		ENTRENAMIENTO	VALIDACIÓN
0,2	100000	0,001729	0,009794
0,1	71000	0,000554	0,010142
0,01	31000	0,000536	0,010308
0,001	18000	0,000551	0,010295

Tabla 7.11: Red 4-30-30-1sigmoideal

En comparación con la red 4-20-20-1 se observa que al añadir neuronas en las capas ocultas el error de entrenamiento sigue disminuyendo como ocurría con el mismo caso pero con una sola capa oculta, pero el error de validación empieza a aumentar ligeramente ya que se va

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

separando del error del error de entrenamiento (ver figura 7.17). Por lo tanto se deduce que es mejor con 20 neuronas en la capa oculta ya que los errores se mantienen más próximos.

7.8.6. RED 4-25-25-25-1

El último análisis que se ha realizado ha sido con la red 4-25-25-25-1, es decir, se ha añadido una tercera capa oculta. Debido a la complejidad computacional solamente se ha realizado este análisis con tres capas ocultas y se han obtenido conclusiones a partir de los análisis anteriores. Las características de esta red son las siguientes:

- Capa de entrada: una capa de entrada con 4 neuronas.
- Capa oculta: tres capas ocultas con 25 neuronas en cada capa.
- Capa de salida: una capa de salida con 1 neurona.
- Función de activación: sigmoideal.

El mayor cambio realizado con respecto a las otras redes es que en este caso se dispone de una tercera capa oculta. La capa de entrada y la capa de salida se mantienen de nuevo sin cambios y la función de activación al igual que en los últimos análisis es la función sigmoideal. El otro cambio es el número de neuronas en las capas ocultas, se ha escogido 25 neuronas en cada una de las tres capas porque es un número intermedio entre las neuronas de las dos últimas redes (20 y 30 neuronas respectivamente). En la figura 7.18 se muestra un fragmento de esta red antes del aprendizaje.




Figura 7.18: Red 4-25-25-25-1 sin entrenar

A continuación se realiza el entrenamiento de la red obteniendo el MSE de los datos de validación y el de los datos de entrenamiento (ver figura 7.19). El número de ciclos escogido en esta ocasión es el mismo que en los análisis con dos capas ocultas para cada factor de

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

aprendizaje. Las oscilaciones de los errores son algo menores en el error de validación y, al igual que ocurría en la red 4-30-30-1, se separa del error de entrenamiento a medida que avanza el número de ciclos. Otra peculiaridad que se observa en la gráfica de error es que al modificar el factor de entrenamiento de 0,1 a 0,01 ya casi no se observa variación cuando, en otras redes, aunque fuese pequeño sí que se observaba. En la figura 7.19 se muestra la gráfica de error correspondiente a esta red.




Figura 7.19: Gráfica de error red 4-25-25-25-1

Ya en la gráfica se observa que el valor del error de entrenamiento disminuye considerablemente, sobre todo en la última parte de la gráfica (a partir del cambio del factor de entrenamiento de 0,2 a 0,1). Sin embargo, para conseguir valores exactos es necesario obtener el archivo “log” del JavaNNS y analizar los valores numéricos de cada error. Estos valores se resumen en la tabla 7.12.

RED 4-25-25-25-1 SIGMOIDAL			
FACTOR DE ENTRENAMIENTO (η)	Nº DE CICLOS	ERROR CUADRÁTICO MEDIO (MSE)	
		ENTRENAMIENTO	VALIDACIÓN
0,2	100000	0,001124	0,004407
0,1	71000	0,000054	0,004568
0,01	31000	0,000035	0,004924
0,001	18000	0,000034	0,004952

Tabla 7.12: Red 4-25-25-25-1 sigmoideal

A partir de estos análisis realizados se pueden sacar una serie de conclusiones que se explican con detalle en el último capítulo del Trabajo, “Conclusiones y Trabajos Futuros”.

CAPÍTULO 8

CONCLUSIONES Y TRABAJOS FUTUROS

8.1. INTRODUCCIÓN

El objetivo de este capítulo es, en primer lugar, hacer un resumen de las conclusiones obtenidas en el presente Trabajo de Fin de Grado, al realizar el modelado inverso de un amortiguador MR utilizando el software de redes neuronales JavaNNS. En segundo lugar, se van a mencionar algunas posibles aplicaciones de estos resultados en trabajos futuros.

8.2. CONCLUSIONES

En este Trabajo de Fin de Grado se han analizado diferentes tipologías de redes neuronales para encontrar la más recomendable para el modelado de un amortiguador MR inverso, es decir, aquel que estima la corriente a la que se debe alimentar el amortiguador MR para conseguir una determinada fuerza. Al final de cada análisis se ha incluido una tabla-resumen de los resultados obtenidos. Algunas de las conclusiones se han ido mencionando a lo largo de los análisis de redes realizados, pero con este capítulo lo que se pretende es reunir y resumir todas ellas para que queden claras. Por lo tanto, las conclusiones a las que se llegan tras la realización de este Trabajo son las siguientes:

- a) Número óptimo de capas ocultas en la red: En el modelado inverso de un amortiguador MR utilizando redes neuronales es mejor tener al menos dos capas ocultas. Tras los estudios realizados se observa que al ir aumentando las capas ocultas tanto el error de entrenamiento como el error de validación son menores. Esto quiere decir que la red aprende mejor cuantas más capas ocultas tiene, es decir, que los resultados obtenidos se aproximan más a los resultados deseados.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

- b) Número óptimo de neuronas en las capas ocultas: El número de neuronas en las capas ocultas modifica el resultado obtenido. En este caso hay que tener cuidado con las neuronas que se colocan en las capas ocultas, ya que cuando se tenía una sola capa oculta, al ir aumentando las neuronas los resultados mejoraban. Sin embargo, como se ha podido comprobar, al tener más de una capa oculta si se colocaban demasiadas neuronas los errores de validación y de entrenamiento se iban separando. Por lo tanto, en este caso el número ideal de neuronas en las capas ocultas es de entre 20 y 25 neuronas. Sin embargo, esto no es un número concreto, depende de los datos utilizados para validar y entrenar.
- c) Factor de entrenamiento o aprendizaje: La variación del factor de entrenamiento modifica el error. Lo mejor es empezar por un factor de 0,2 y esperar a que el error de entrenamiento se estabilice (el error de validación en general se estabiliza primero) y después ir disminuyendo el factor poco a poco. El aprendizaje se detiene cuando al variar el factor de entrenamiento el error se mantiene prácticamente constante (en estos análisis se ha detenido siempre al llegar a un factor de 0,001).
- d) Número de ciclos: El número de ciclos también afecta al entrenamiento de la red. Normalmente, para redes sencillas el número de ciclos que se necesita para que el error se estabilice es más pequeño que para redes complejas. Por eso se recomienda que el número de ciclos se varíe en función de la complejidad de la red neuronal.
- e) Función de activación: La función de activación elegida es importante para los resultados obtenidos. En el caso de un amortiguador MR inverso lo más adecuado es utilizar la función sigmoideal en la capa de entrada, función logística en las capas ocultas y función identidad en la capa de salida. Sin embargo, la utilización de la función tangente hiperbólica en la capa de entrada no modificaría demasiado los resultados.
- f) Red recomendada: A partir de los apartados anteriores se llega a la conclusión final de que la mejor tipología de red para estos datos es una red con tres capas ocultas y entre 20 y-25 neuronas en cada capa oculta, que utilice la función de activación sigmoideal en la capa de entrada y que se entrene a lo largo de un alto número de ciclos.

8.3. TRABAJOS FUTUROS

Todos los análisis se han realizado sobre un amortiguador MR colocado en un banco de pruebas en estático. Aunque se tiene en cuenta la velocidad del amortiguador, sería interesante poder realizar estos análisis en dinámico, es decir, con el vehículo en movimiento para ver en un caso algo más real el comportamiento de este amortiguador.

Por otro lado, teniendo en cuenta que la temperatura afecta a los fluidos MR se podría realizar el mismo estudio pero teniendo en cuenta la temperatura. En este Trabajo no se ha tenido en cuenta este parámetro. Si se tuviese en cuenta, al variar la temperatura también variarían las propiedades del fluido que circula por el cilindro del amortiguador lo que podría afectar al comportamiento de éste.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

BIBLIOGRAFÍA

- [1] FERNÁNDEZ VIVEROS, Alfonso. Año 2012. Proyecto Fin de Carrera. “Modelos de un amortiguador magneto-reológico”. Dirección: Dra. M^a Jesús López Boada. Universidad Carlos III de Madrid.
- [2] LÓPEZ FERNÁNDEZ, David. Año 2010. Proyecto Fin de Carrera. “Montajes y estudio de un amortiguador magneto-reológico RD 1500.3 en la suspensión de un vehículo automóvil”. Dirección: Dra. M^a Jesús López Boada. Universidad Carlos III de Madrid.
- [3] CORONEL BENAVENTE, Diego. Año 2010. Proyecto Fin de Carrera. “Montaje y estudio de un amortiguador magneto-reológico en la suspensión de un vehículo automóvil”. Dirección: Dra. M^a Jesús López Boada. Universidad Carlos III de Madrid.
- [4] MUÑOZ ÁGUILA, Felipe Borja. Año 2012. Proyecto Fin de Carrera. “Modelo directo no paramétrico de amortiguador magneto-reológico utilizando redes neuronales”. Dirección: Dra. M^a Jesús López Boada. Universidad Carlos III de Madrid.
- [5] ARRANZ IGLESIAS, Javier. Año 2011. Proyecto Fin de Carrera. “Simulación del comportamiento de varios modelos de amortiguadores magneto-reológicos mediante Modelica”. Dirección: Dra. M^a Jesús López Boada. Universidad Carlos III de Madrid.
- [6] RODRÍGUEZ CADENAS, Rubén. Año 2012. Proyecto Fin de Carrera. “Modelado de un amortiguador magneto-reológico mediante Ecosimpro”. Dirección: Dra. Esther Olmeda Santamaría. Universidad Carlos III de Madrid.
- [7] “Sistema de suspensión” Disponible en:
<http://mecanicayautomocion.blogspot.com.es/2009/03/sistema-de-suspension.html>
- [8] PÉREZ, CARLOS. “Sistema de suspensión” *Slideshare*. Disponible en:
<http://www.slideshare.net/CarlosPerezS/sistema-de-suspension-9489590>
- [9] “Aficionados a la mecánica”. Blog.
<http://www.aficionadosalamecanica.net>
- [10] “km 77”. Página web.
<http://www.km77.com/glosario>
- [11] “Sistema de suspensión”. *Grupo de investigación IMAC: Ingeniería Mecánica Aplicada y Computacional*. Disponible en:
http://www.imac.unavarra.es/web_imac/pages/docencia/assignaturas/maquinas-iti/Trabajos/Amortiguadores.pdf
- [12] Empresa TEJASA ANTIVIBRACIÓN especializada en *silentblocks*
<http://www.silentblock.es/>

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

[13] “Motorgiga”. Diccionario web.

<http://diccionario.motorgiga.com/diccionario>

[14] ALBERDI URBIETA, Juan. Año 2003. “Manual de automoción- Amortiguadores y suspensión”. *TECNUN*, Campus Tecnológico de la Universidad de Navarra.

http://www.tecnun.es/automocion/files/ebooks/Amortiguadores_y_suspension.pdf

[15] MAYZ ACOSTA, Edgar. “Conocimientos básicos del automóvil”.

<http://www.automotriz.net/tecnic/conocimientos-basicos-37.html>

[16] “El Aula del Profesor Gutiérrez”. Blog.

<http://elauladelprofesorgutierrez.blogspot.com.es/2012/04/suspension-rigida.html>

[17] Compañía CRUMEX CHASSIS PARTS.

<http://www.e-auto.com.mx/engew/index.php/boletines-tecnicos/general/85-boletines-tecnicos/3497-sistemas-de-suspension>

[18] HUREL, Jorge; MANDOW, Anthony y GARCÍA, Alfonso. Año 2013. “Los sistemas de suspensión activa y semiactiva: una revisión”, *Sciverse ScienceDirect*.

http://apps.elsevier.es/watermark/ctl_servlet? f=10&pident_articulo=90195906&pident_usuario=0&pcontactid=&pident_revista=331&ty=75&accion=L&origen=elsevierpt%20&web=http://www.elsevierciencia.es&lan=es&fichero=331v10n02a90195906pdf001.pdf

[19] “Reología”. *ARQHYS ARQUITECTURA*. Disponible en:

<http://www.arqhys.com/construccion/reologia.html>

[20] “Conceptos básicos de reología”. Web del profesor; ingeniería. Disponible en:

<http://webdelprofesor.ula.ve/ingenieria/mabel/materias/sistemdispersos/Reologia.pdf>

[21] “Materiales inteligentes” y “Fluidos reológicos”. ACIMAT. Disponibles en:

<http://www.actimat.es/web/materiales-inteligentes.asp>

<http://www.actimat.es/web/magnetoreologicos.asp>

[22] PHILLIPS, Tony y BARRY, Patrick L. “Asombrosos fluidos magnéticos”. Año 2003. *CIENCIA@NASA*.

http://ciencia.nasa.gov/science-at-nasa/2003/02apr_robotblood/

[23] BRAVO, E.; CHACÓN, P. y RIVAS, F. “Amortiguadores magneto-reológicos” (capítulo II- fluidos magneto-reológicos). *Universidad Politécnica Salesiana (UPS) de Ecuador*.

<http://dSPACE.ups.edu.ec/bitstream/123456789/826/4/CAPITULO2.pdf>

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

- [24] MESQUIDA, CÉSAR D.; LASSIG, JORGE.L. Año 2011. “Introducción a los fluidos magneto-reológicos con aplicaciones a la ingeniería”. *Revista Iberoamericana de Ingeniería Mecánica*. Universidad Nacional de Comahue, Buenos Aires, Argentina.
- <http://www.uned.es/ribim/volumenes/Vol16N1Abril2012/V16N1A03%20Laessig%20%2027-36.pdf>
- [25] “Non- parametric models for magneto-rheological dampers” *Librería virtual de University of Virginia Tech*. Disponible en:
- <http://scholar.lib.vt.edu/theses/available/etd-111299-170915/unrestricted/Chapter3ETD-Modified.pdf>
- [26] SAHIN, I., ENGIN, T. y CESMECI, S. Año 2010. “Comparison of some existing parametric models for magneto-rheological fluid dampers”. *IOP Science*.
- <http://web.sakarya.edu.tr/~engint/yayinlar/A/A13.pdf>
- [27] MEDINA, José; MARICHAL, Manuel; MORALES, Simón. Año 2011. “Desarrollo de dos modelos inversos de un amortiguador magneto-reológico para el control de vibraciones en estructuras civiles”. *SCIELO (Scientific Electronic Library Online)*. Universidad de Venezuela.
- http://www.scielo.org.ve/scielo.php?script=sci_arttext&pid=S0376-723X2008000200001&lng=pt&nrm=iso&tlng=pt
- [28] TABLADA, Claudio Javier; ARIEL TORRES, Germán. “Redes Neuronales Artificiales”. Universidad Nacional de Córdoba.
- http://www.fis.uncor.edu/rev_edu/documents/vol_24/24_3_redes.pdf
- [29] GERSHENSON, Carlos. “Artificial Neural Networks for Beginners”. Cornell University Library.
- <http://arxiv.org/ftp/cs/papers/0308/0308031.pdf>
- [30] STERGIOU, Christos; SIGANOS, Dimitrios. “Neural Networks”. Imperial College London.
- http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html
- [31] MATICH, Damián Jorge. “Redes neuronales: conceptos básicos y aplicaciones”. Universidad Tecnológica Nacional- Facultad Regional Rosario.
- <ftp://decsai.ugr.es/pub/usuarios/castro/Material-Redes-Neuronales/Libros/matich-redesneuronales.pdf>
- [32] “Regla de aprendizaje *Backpropagation*”. Universidad de Guadalajara- Centro Universitario de Ciencias Exactas e Ingeniería.
- <http://proton.ucting.udg.mx/posgrado/cursos/idc/neuronales2/ReglaB.htm>

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

[33] Manual JavaNNS y SNNS

[34] Seguros ARPEM.

<http://www.arpem.com/coches/coches/opel/insignia/fotos/2009/opel-insignia-sports-tourer-ilustracion-suspension.html>

[35] Fondo de Coches de rally

<http://www.fondospedia.com>

[36] Plataforma Educativa Aragonesa

http://educativa.catedu.es/44700165/aula/archivos/repositorio/1000/1103/html/3_elementos_elsticos.html

[37] Mecánica Virtual

<http://www.mecanicavirtual.com>

[38] Rapid Racer- Suspensión

<http://www.rapid-racer.com/suspension.php>

[39] Suspensión automotriz 1993. Disponible en:

<http://suspensionautomotriz1993.blogspot.co.uk/2012/09/suspension-automotriz.html>

[40] Autos y motos. *Taringa*.

<http://www.taringa.net/posts/autos-motos/14025403/Amortiguacion-pensada---sistemas-inteligentes.html>

[41] CUMARE, Ronald. “Instrumentos de medición”. *Mecatrónica virtual*. Venezuela.

<http://instrumentosdemedicion.blogspot.co.uk/2008/07/mano-robot.html>

[42] Diseño de prótesis del miembro inferior. Monografías.

<http://www.monografias.com/trabajos93/disenio-protesis-del-miembro-inferior/disenio-protesis-del-miembro-inferior.shtml>

[43] Suspensión con ballestas. *Coches RAM*.

http://es.ramtrucks.com/en/2013/ram_3500/capability/

[44] Barra estabilizadora. *Glosario USA Auto Parts Export*-

<http://usaautopartsexport.com/glosario/>

[45] BMW. *Ymods*.

<http://bmwymods.es/poliuretano.html>

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO- REOLÓGICO UTILIZANDO REDES NEURONALES

[46] La neurona”. Educación de Chile. Disponible en:

<http://www.educarchile.cl/ech/pro/app/detalle?ID=137486>

ANEXO A

TUTORIAL JAVANNS

El objetivo de este anexo es dar a conocer el software utilizado en el proyecto, JavaNNS. Para ello, se ha realizado un pequeño tutorial siguiendo un ejemplo de red sencilla para explicar los comandos utilizados durante el entrenamiento de la red [33].

A.1. INTRODUCCIÓN

JavaNNS (*Java Neural Network Simulation*) es un software desarrollado por la Universidad de Tübingen (Stuttgart- Alemania). Es la continuación del simulador de redes neuronales SNNS (*StuttgartNeural Network Simulation*) pero utilizando una interfaz Java. Esta versión es mucho más sencilla e intuitiva que su predecesora, pudiendo realizar prácticamente las mismas aplicaciones que ésta a excepción de aquellas más complicadas. Sin embargo, para este proyecto la versión Java es suficiente.

Este software permite tanto la creación como el entrenamiento y validación de redes neuronales. En primer lugar es necesario haber recopilado datos suficientes para entrenar y para validar la red, para lo cual se necesitarán dos ficheros independientes, uno de entrenamiento y otro de validación. Por otro lado se tiene que crear la red, sabiendo el número de neuronas de entrada y de salida que se necesitan es bastante sencillo realizarlo. Una vez que se tienen los datos preparados y la red creada puede comenzar el entrenamiento, analizando la gráfica de error y variando el factor de entrenamiento cuando sea conveniente.

En la figura A.1 se muestra cómo es el software, en ella se observa una gráfica de error, una gráfica de pesos, el panel de control y los errores que se van obteniendo a medida que se entrena la red en la ventana “log” del programa.

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

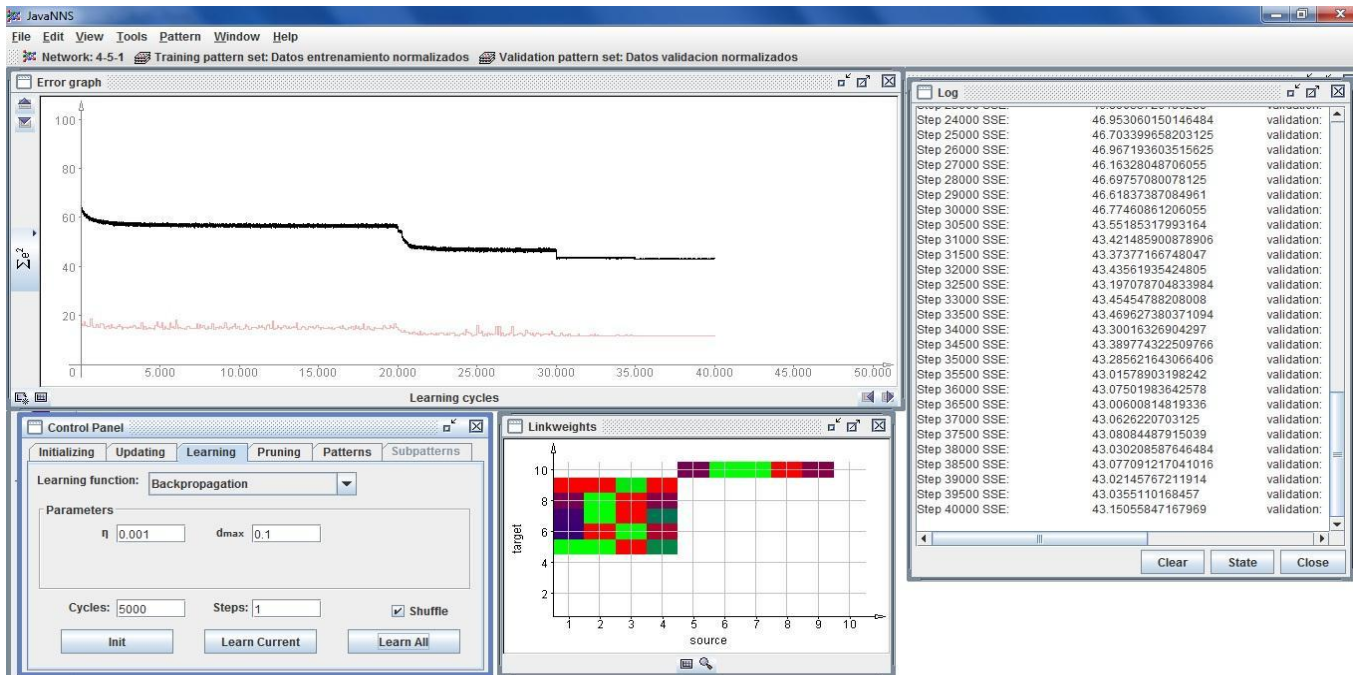


Figura A.1: Interfaz JavaNNS

A continuación se explica detalladamente cada uno de los pasos seguidos para realizar el entrenamiento de una red neuronal en JavaNNS.

A.2. CREAR UNA RED NEURONAL ARTIFICIAL EN JAVANNS

La creación de redes neuronales artificiales en JavaNNS es bastante sencilla. En el menú *TOOLS* se selecciona *CREATE-LAYERS*. En la ventana que se abre (ver figura A.2) se pueden crear cada una de las capas de la red, se selecciona el número de neuronas que se quieren en cada capa (*height*) y si es una capa de entrada (*input*), capa oculta (*hidden*) o capa de salida (*output*). Además, en esta misma ventana, se puede seleccionar la función de activación de cada capa.

En la figura A.2 se muestra cómo acceder a la ventana mencionada y las distintas opciones que pueden modificarse.

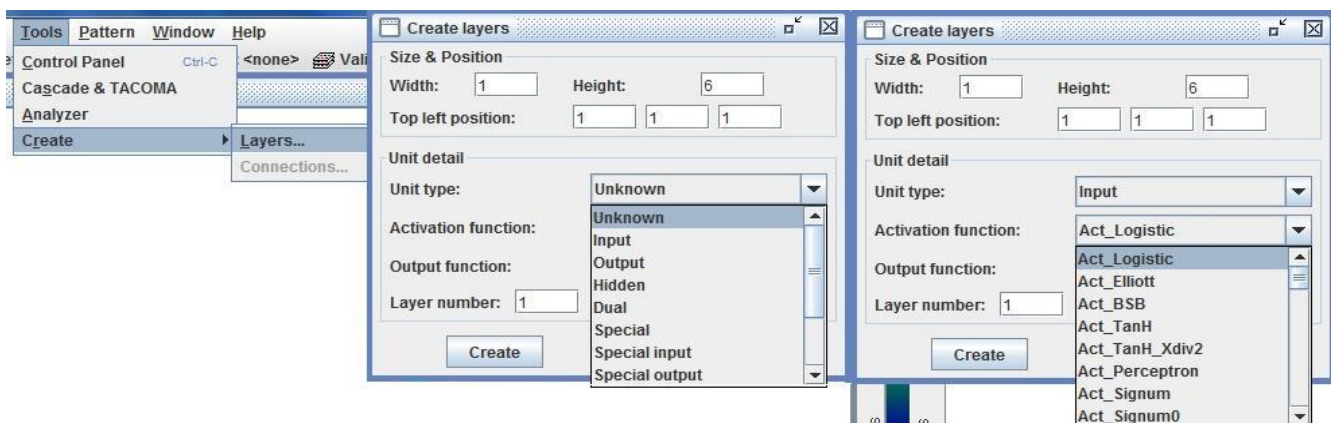


Figura A.2: Crear capas de redes neuronales

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

El software permite la creación de redes neuronales sencillas y redes mucho más complicadas. En el ejemplo de este tutorial se ha creado una red muy sencilla para poder comprender los principios básicos del programa. Se ha creado una red 4-5-1, es decir, cuatro neuronas en la capa de entrada, cinco en la única capa oculta que tiene y una neurona en la capa de salida (ver figura A.3).




Figura A.3: Red 4-5-1

En la figura A.4 se ha creado una red más compleja simplemente a modo de ejemplo de red con más capas ocultas, se trata de una red 6-10-10-10-3. Es decir, 6 neuronas en la capa de entrada, 10 neuronas en cada una de las 3 capas ocultas y 3 neuronas en la capa de salida.




Figura A.4: Red 6-10-10-10-3

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

A.3. CONEXIONES ENTRE NEURONAS

Las conexiones entre neuronas se realizan en el mismo menú dónde se crean las capas de la red, es decir, en *TOOLS* se selecciona *CREATE* pero esta vez se elige *CONNECTIONS*. En este proyecto se utiliza la conexión *feed-forward* para que la entrada de una neurona sea la salida de la anterior y así sucesivamente (ver figura A.5).

En la figura A.5 se muestran los paneles para realizar las conexiones entre neuronas, primero el modo de llegar a la ventana de conexiones y luego el panel en el cual se selecciona el tipo de conexión.

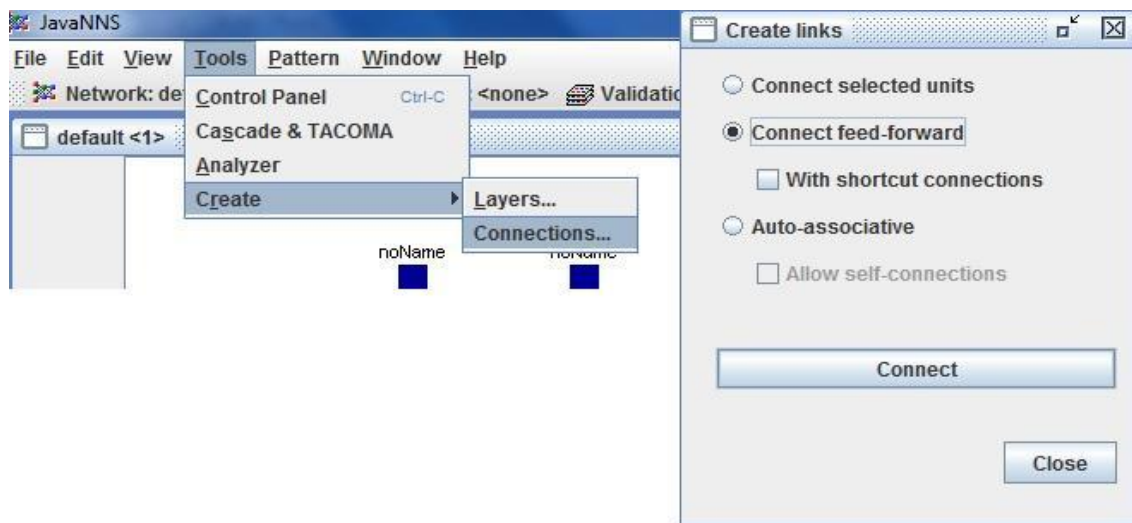


Figura A.5: Conexiones entre neuronas

En la figura A.6 se muestra la red correspondiente al ejemplo del tutorial (la red 4-5-1) pero ya con las conexiones creadas.




Figura A.6: Red 4-5-1 con conexiones

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

En la figura A.7 se muestra la red con varias capas ocultas creada en la sección A.2 ya con todas las conexiones. De esta manera puede observarse la complejidad de la red.




Figura A.7: Red 6-10-10-10-3 con conexiones

A.4. PATRONES DE ENTRENAMIENTO Y DE VALIDACIÓN

Para poder entrenar la red neuronal hay que introducir los datos en el software, pero para ello hay que depurarlos y prepararlos para una correcta lectura por parte del programa.

En primer lugar hay que crear dos documentos, uno con los datos de entrenamiento y otro con los datos de validación. Los primeros se utilizan para entrenar la red y los otros para comprobar que se ha entrenado correctamente.

Se deben crear dos ficheros de texto con extensión .txt, uno para cada conjunto de datos (validación y entrenamiento). En esos ficheros debe aparecer la cabecera que se muestra en la

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

figura A.7. En esta cabecera aparecen el número de neuronas de entrada (*No. of inputs units*), el de salida (*No. of output units*) y el número total de cada conjunto de datos (*No. of patterns*).

Estos documentos de textos tienen que tener tantas columnas como neuronas de entrada y de salida haya. Es decir, en el ejemplo hay cuatro neuronas de entrada y una de salida, por lo tanto, cada documento de texto tiene cinco columnas (ver figura A.8). Es importante tener en cuenta que estas columnas deben estar separadas por espacios para que el programa identifique los datos de cada neurona.

En la figura A.8 (izquierda) se muestran los datos de entrenamiento para la red del ejemplo 4-5-1 y en la figura A.8 (derecha) los datos de validación de dicha red. Como puede verse en la cabecera, se trata de una red con cuatro entradas y una salida. En el caso del patrón de entrenamiento hay 2569 elementos y en el caso de la validación hay 644 datos.

Datos entrenamiento normalizados: Bloc de notas

Archivo Edición Formato Ver Ayuda

SNNS pattern definition file V4.2
generated at Fri Sep 13 11:40:34 2013

No. of patterns : 2569
No. of input units : 4
No. of output units : 1

-0.07197	0.00000	0.00000	0.05556	0.00000
-0.28787	-0.04769	-0.03994	0.05556	0.00000
-0.49168	-0.04398	-0.04130	0.05556	0.00000
-0.66852	-0.03771	-0.04474	0.05556	0.00000
-0.80749	-0.02919	-0.04546	0.05556	0.00000
-0.90880	-0.01995	-0.04714	0.05556	0.00000
-0.96490	-0.01029	-0.04349	0.05556	0.00000
-0.98097	-0.00087	-0.04159	0.05556	0.00000
-0.94330	0.01176	0.01276	0.05556	0.00000
-0.85091	0.02280	0.04248	0.05556	0.00000
-0.71630	0.03241	0.04555	0.05556	0.00000
-0.54481	0.03980	0.04663	0.05556	0.00000
-0.34675	0.04632	0.05014	0.05556	0.00000
-0.13026	0.04919	0.05152	0.05556	0.00000
0.09238	0.04968	0.05468	0.05556	0.00000
0.30848	0.04764	0.05562	0.05556	0.00000
0.50971	0.04377	0.06070	0.05556	0.00000
0.68001	0.03699	0.05954	0.05556	0.00000
0.82176	0.02912	0.06132	0.05556	0.00000
0.91832	0.01973	0.06094	0.05556	0.00000
0.97383	0.00975	0.06094	0.05556	0.00000
0.98314	-0.00071	0.04710	0.05556	0.00000
0.94131	-0.01281	-0.02241	0.05556	0.00000
0.84655	-0.02348	-0.02537	0.05556	0.00000
0.71014	-0.03314	-0.02822	0.05556	0.00000
0.53667	-0.04117	-0.03068	0.05556	0.00000
0.33524	-0.04720	-0.03518	0.05556	0.00000
0.11577	-0.04892	-0.03778	0.05556	0.00000
-0.10290	-0.04921	-0.03889	0.05556	0.00000

Datos validacion normalizados: Bloc de notas

Archivo Edición Formato Ver Ayuda

SNNS pattern definition file V4.2
generated at Fri Sep 13 11:40:34 2013

No. of patterns : 644
No. of input units : 4
No. of output units : 1

-0.28277	-0.04847	-0.04059	0.05556	0.00000
-0.90807	-0.02055	-0.04805	0.05556	0.00000
-0.85246	0.02302	0.04330	0.05556	0.00000
-0.13206	0.04987	0.05260	0.05556	0.00000
0.67931	0.03756	0.06071	0.05556	0.00000
0.98550	-0.00078	0.04845	0.05556	0.00000
0.53832	-0.04188	-0.03126	0.05556	0.00000
-0.59353	0.07654	0.05122	0.11111	0.00000
0.89496	0.04917	0.06905	0.11111	0.00000
0.17514	-0.09716	-0.04542	0.11111	0.00000
-0.97637	-0.00850	-0.03973	0.11111	0.00000
0.28098	0.09812	0.06650	0.11111	0.00000
0.87510	-0.03740	-0.02836	0.11111	0.00000
-0.66660	-0.07818	-0.04785	0.11111	0.00000
-0.54746	0.07797	0.05109	0.11111	0.00000
-0.67812	0.10062	0.05162	0.16667	0.00000
0.93169	-0.01881	-0.01062	0.16667	0.00000
-0.97498	-0.03210	-0.04416	0.16667	0.00000
0.86636	0.08873	0.07266	0.16667	0.00000
-0.60823	-0.13152	-0.05752	0.16667	0.00000
0.23033	0.15059	0.07286	0.16667	0.00000
0.19281	-0.14524	-0.05452	0.16667	0.00000
-0.79170	-0.14679	-0.06098	0.22222	0.00000
0.96227	0.07025	0.07052	0.22222	0.00000
-0.95175	0.00343	-0.03991	0.22222	0.00000
0.70333	-0.11966	-0.03754	0.22222	0.00000
-0.30640	0.17636	0.07489	0.22222	0.00000
-0.14615	-0.20165	-0.07450	0.22222	0.00000
0.57823	0.18534	0.08774	0.22222	0.00000

Datos entrenamiento

Datos validación

Figura A.8: Ejemplo patrón de entrenamiento y de validación

Una vez creados los documentos de texto, deben cambiarse de extensión a una extensión .pat que es la que corresponde a los patrones de datos en el programa. Para ello, en la barra del software se selecciona *OPEN* y se abre uno de los documentos .txt y después se elige *SAVE DATA* y se guarda como .pat. Cada vez que se vaya a entrenar una red se abren los dos documentos .pat (el de entrenamiento y el de validación) y se comprueba que se han leído correctamente, deben aparecer en la cabecera como se muestra en la figura A9.




Figura A.9: Datos entrenamiento y validación reconocidos por el software

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

A.5. ENTRENAMIENTO DE UNA RED NEURONAL ARTIFICIAL

Para entrenar una red neuronal hay que utilizar el panel de control, desde *TOOLS* se selecciona *CONTROL PANEL* (ver figura A.10). En la primera pestaña del panel de control (*initializing*) se pueden inicializar los pesos, en este caso se seleccionan pesos aleatorios (*random weights*) y se presiona en *init* para que se inicien.

En la figura A.9 se muestra cómo llegar hasta el panel de control y dónde se inicializan los pesos.

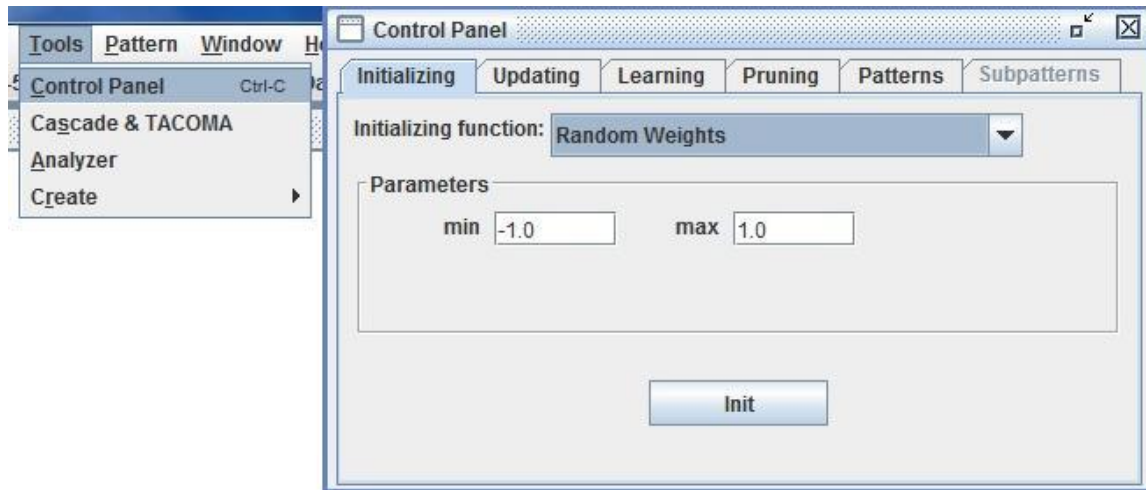


Figura A.10: Inicializar pesos en el panel de control

El siguiente paso a realizar es asegurarse de que el programa ha leído correctamente los patrones de entrenamiento y validación. En la pestaña *patterns* de este panel se seleccionan los archivos correspondientes y, si todo está bien, aparecerán en la cabecera como se explicó en la sección A.4.

En la figura A.11 se muestra la pestaña *patterns* con los datos con extensión .pat seleccionados, los de entrenamiento y los de validación cada uno donde le corresponde.

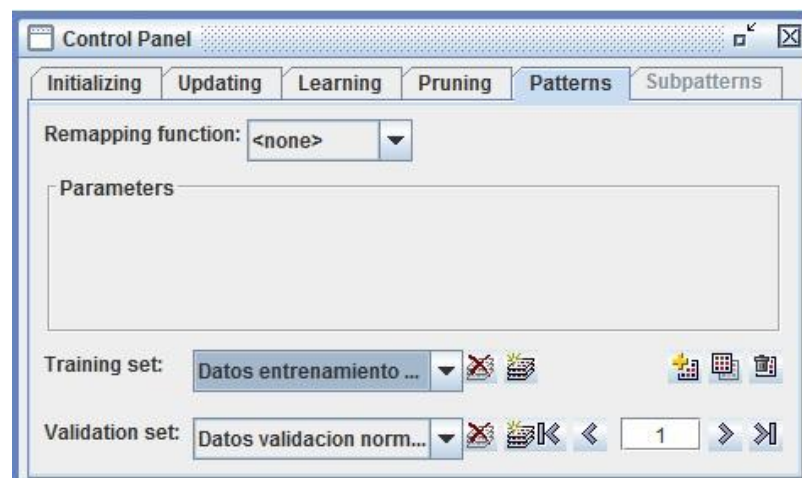


Figura A.11: Pestaña *patterns* del panel de control

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

La siguiente pestaña de gran importancia es la pestaña *learning* en la cual se realizará el entrenamiento y aprendizaje de la red. En esta ventana se selecciona la función de entrenamiento que se va a utilizar, en este caso en la función *backpropagation* (ver sección 6.3.3). A continuación se selecciona el factor de entrenamiento (lo normal es empezar por 0,2) y después el número de ciclos. En este ejemplo además se ha seleccionado la casilla *shuffle*, es decir, que va a leer los datos aleatoriamente y no en el orden que tienen en el documento .pat.

La figura A.12 muestra la pestaña *learning* del panel de control con un factor de entrenamiento de 0,2, 100 ciclos y marcada la casilla *shuffle*.

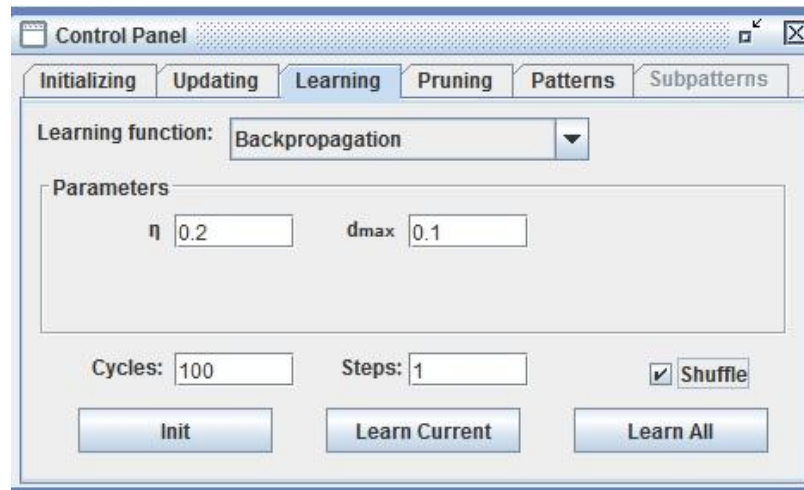


Figura A.12: Pestaña *learning* del panel de control

A.6. GRÁFICA DE ERROR

La gráfica de error sirve para analizar el buen o mal entrenamiento de la red, a través de ella se sabe si esa red es la más adecuada para esos datos o si es preferible cambiarla por otra con más neuronas o más capas ocultas o quizás hay que cambiar la función de activación de las neuronas. Es importante tener la gráfica abierta mientras se entrena la red porque de esta manera se va viendo como aumenta o disminuye el error. Para abrirla, desde el menú se pulsa *VIEW-ERROR GRAPH*.

El error va disminuyendo a medida que se entrena la red hasta que consigue estabilizarse, en ese momento hay que cambiar el factor de entrenamiento para ver si el error disminuye e ir cambiándolo hasta que se consigue el menor error posible con esa red y esos datos. Este comportamiento de la red se observa en la figura A.13.

En la figura A.13 se ha empezado entrenando la red con un factor de entrenamiento de 0,2 durante 20000, después se ha disminuido a 0,1 durante 10000 ciclos, a continuación a 0,01 durante 5000 ciclos y, por último, a 0,001 durante otros 5000 ciclos. Se observa que en el último cambio de factor no hay apenas diferencia en el error con respecto al anterior, por eso se ha

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

parado ahí. Esta red no sería buena para este conjunto de datos pues el error final que se consigue es muy alto (en torno a 42), había que cambiar la tipología de la red.





Figura A.13: Gráfica de error de la red 4-5-1


A.7. PESOS EN LA RED NEURONAL

Cada conexión de cada neurona con la siguiente capa lleva asignada un peso. En el momento de entrenar la red se asigna un valor aleatorio de los pesos pero mientras se entrena la red éstos van cambiando hasta alcanzar su valor final.

En la figura A.14 se muestran los pesos de la red del ejemplo 4-5-1 cuando valen cero (figura A.14 izquierda) y los pesos cuando ya se ha entrenado la red (figura A.14 derecha).



Pesos con valor cero



Pesos con la red entrenada

Figura A.14: Gráficas de pesos

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

A.8. RED ENTRENADA Y RESULTADOS

Finalmente cuando la red está entrenada aparecen en ella los pesos de las conexiones entre neuronas así como un código de color que se indica a la izquierda de la pantalla dónde indica el correspondiente valor. En la figura A.15 se muestra la red 4-5-1 entrenada.

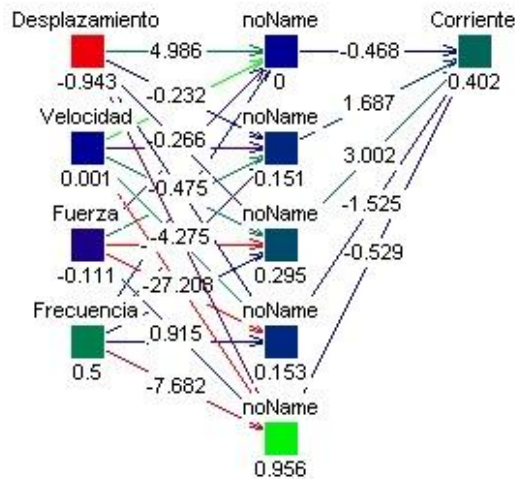


Figura A.15: Red 4-5-1 entrenada

Para guardar los resultados de la red entrenada se utiliza en el menú *SAVE AS* y se guarda con extensión .net.

También pueden guardarse los datos de la red entrenada con extensión .res en *SAVE DATA*. Si luego se abre este archivo con un editor de texto (o se le cambia la extensión a .txt) se pueden ver los resultados. En la figura A.16 se muestra el documento de texto creado al cambiar de extensión el archivo .res.

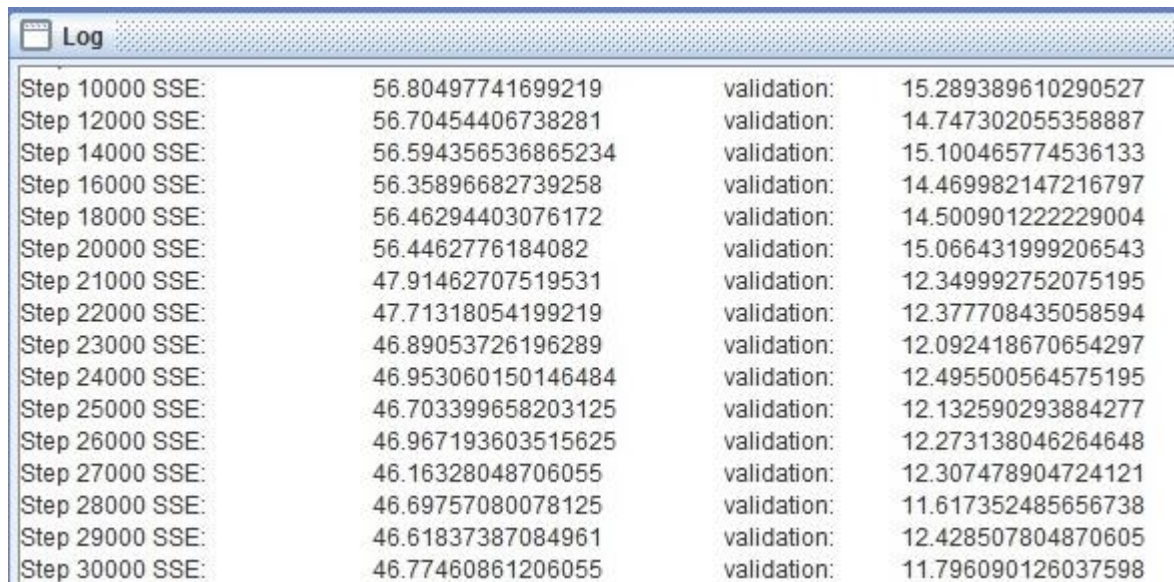
```
SNNS result file v1.4-3D
generated at Mon Sep 23 18:43:21 2013

No. of patterns      : 2569
No. of input units  : 4
No. of output units : 1
startpattern        : 1
endpattern          : 2569
input patterns included
teaching output included
#1.1
-0.07197 0 0 0.05556
0
0.04875
#2.1
-0.28787 -0.04769 -0.03994 0.05556
0
0.02809
#3.1
-0.49168 -0.04398 -0.0413 0.05556
0
0.02226
#4.1
-0.66852 -0.03771 -0.04474 0.05556
0
0.02176
```

Figura A.16: Documento de texto del archivo .res

MODELO INVERSO DE UN AMORTIGUADOR MAGNETO-REOLÓGICO UTILIZANDO REDES NEURONALES

Además hay otro archivo que se va creando a lo largo del entrenamiento de la red y el cual es conveniente abrirlo durante el entrenamiento al igual que la gráfica de error. Se trata del archivo “log” dónde se van marcando los errores de validación y de entrenamiento de la red a cada ciclo. Se abre desde *VIEW-LOG* y para guardarlo hay que seleccionar *SAVE DATA* y poner la extensión .log, éste archivo se guarda como un documento de texto. En la figura A.17 se muestra la ventana “log”,



Log			
Step 10000 SSE:	56.80497741699219	validation:	15.289389610290527
Step 12000 SSE:	56.70454406738281	validation:	14.747302055358887
Step 14000 SSE:	56.594356536865234	validation:	15.100465774536133
Step 16000 SSE:	56.35896682739258	validation:	14.469982147216797
Step 18000 SSE:	56.46294403076172	validation:	14.500901222229004
Step 20000 SSE:	56.4462776184082	validation:	15.066431999206543
Step 21000 SSE:	47.91462707519531	validation:	12.349992752075195
Step 22000 SSE:	47.71318054199219	validation:	12.377708435058594
Step 23000 SSE:	46.89053726196289	validation:	12.092418670654297
Step 24000 SSE:	46.953060150146484	validation:	12.495500564575195
Step 25000 SSE:	46.703399658203125	validation:	12.132590293884277
Step 26000 SSE:	46.967193603515625	validation:	12.273138046264648
Step 27000 SSE:	46.16328048706055	validation:	12.307478904724121
Step 28000 SSE:	46.69757080078125	validation:	11.617352485656738
Step 29000 SSE:	46.61837387084961	validation:	12.428507804870605
Step 30000 SSE:	46.77460861206055	validation:	11.796090126037598

Figura A.17: Ventana “log”